

**UNIVERZITA KARLOVA V PRAZE**

**Přírodovědecká fakulta**

Katedra aplikované geoinformatiky a kartografie

Studijní program: Geografie

Studijní obor: Kartografie a geoinformatika



Bc. Kristýna Soudková

**KLASIFIKACE SMRKOVÝCH POROSTŮ S VYUŽITÍM OBRAZOVÉ A  
LABORATORNÍ SPEKTROSKOPIE**

**CLASSIFICATION OF NORWAY SPRUCE BASED ON IMAGING AND  
LABORATORY SPECTROSCOPY**

Diplomová práce

Vedoucí diplomové práce: Ing. Markéta Potůčková, Ph.D.

Praha, 2014

# UNIVERZITA KARLOVA V PRAZE

## Přírodovědecká fakulta

Katedra apl. geoinformatiky a kartografie

### ZADÁNÍ DIPLOMOVÉ PRÁCE

Jméno a příjmení: **Kristýna Soudková**

Datum a místo narození: **17.7.1988, Praha**

Studijní obor: **Kartografie a geoinformatika**

Garant studijního programu/oboru vám schválil přidělení této diplomové práce:

Téma práce: **Klasifikace rekultivovaných oblastí z hyperspektrálních dat metodou linear spectral unmixing**

Anotace

Proved'te klasifikaci vegetačního pokryvu se zaměřením na smrkové porosty v modelových územích vnitřních zón Krkonošského národního parku. Klasifikace bude provedena z hyperspektrálních dat pořízených senzorem APEX. Porovnejte výsledky klasifikačních algoritmů Linear Spectral Unmixing, Support Vector Machine a Spectral Angle Mapper. Ověřte možnost využití dat získaných spektrometrem ASD FieldSpec 4 a kontaktní sondou během pozemní kampaně pro (subpixelovou) klasifikaci hyperspektrálních dat.

Literatura:

ARCHIBALD, R., FANN, G. (2007): Feature Selection and Classification of Hyperspectral Images With Support Vector Machines. *IEEE Geoscience and Remote Sensing Letters*. 2007. roč. 4, č. 4, str. 674 – 677.  
BOVOLO, F., BRUZZONE, L., CARLIN, L. (2010): A Novel Technique for Subpixel Image Classification Based on Support Vector Machine. *Image Processing, IEEE Transactions on*. 2010. roč. 19, č. 11, str. 2983 – 2999.  
MARTIN, M. E., NEWMAN S.D., ABER J. D., CONGALTON R. G. (1998): Determining Forest Species Composition Using High Spectral Resolution Remote Sensing Data. *Remote Sensing of Environment*. 1998. č. 65, str. 249 – 254.  
RICHARDS, J. A., JIA, X. (2006): Remote sensing digital image analysis. Springer-Verlag Berlin Heidelberg, 2006, ISBN-13 978-540-25128-6.

Vedoucí diplomové práce: **Ing. Potůčková Markéta, Ph.D.**

Datum zadání diplomové práce: 21.3.2013

Termín odevzdání diplomové práce: dle harmonogramu příslušného akademického roku

V Praze dne 21.8.2014

.....  
Garant studijního programu/oboru

.....  
Děkan

### **Prohlášení**

Prohlašuji, že jsem závěrečnou práci zpracovala samostatně a že jsem uvedla všechny použité informační zdroje a literaturu. Tato práce ani její podstatná část nebyla předložena k získání jiného nebo stejného akademického titulu.

V Praze dne 27. 8. 2014

.....

Kristýna Soudková

## **Poděkování**

Na tomto místě bych ráda poděkovala Ing. Markétě Potůčkové, Ph.D. za odborné vedení práce, konstruktivní připomínky a vstřícný přístup. Dále pak Mgr. Renátě Suché a Andreasi Huenimu, Dr.sc.nat. za poskytnutá data. V neposlední řadě můj velký dík patří rodině a blízkým za podporu během celého studia a trpělivost v jeho závěru.

## **Abstrakt**

Diplomová práce se zabývá subpixelovou klasifikací hyperspektrálních dat ze senzoru APEX. V rešeršní části jsou popsány algoritmy subpixelové klasifikace a spektrální charakteristiky vegetace. V praktické části je zpracována klasifikace smrkových porostů na osmi stanovištích v oblasti první zóny Krkonošského národního parku. Ke klasifikaci byly využity tři metody řízené klasifikace - Linear Spectral Unmixing, Support Vector Machine a Spectral Angle Mapper. Pro získání koncových členů byla využita data nasbíraná při terénní kampani pomocí kontaktní sondy připojené na přístroj ASD FieldSpec 4 Wide-Res. Pro každé stanoviště byly vytvořeny mapy krajinného pokryvu a zpracovány přesnosti jednotlivých klasifikací.

**Klíčová slova:** hyperspektrální data, subpixelová klasifikace, Linear Spectral Unmixing, Support Vector Machine, Spectral Angle Mapper

## **Abstract**

The master thesis deals with subpixel classification of hyperspectral data from sensor APEX. In the first part there is research from the literature describing algorithms of the subpixel classifications and spectral characteristics of the vegetation. In the practical part there is a work focusing on the classification of the areas with the cover of Norway Spruce trees at eight areas in the Krkonoše national park. Three methods of supervised classification were used – Linear Spectral Unmixing, Support Vector Machine and Spectral Angle Mapper. Field data, spectral curves for exact trees from the eight areas obtained by the contact probe ASD FieldSpec 4 Wide-Res, were used for the extraction of endmembers of the spruces. For each research area maps of land cover were produced by means of the classification methods described above and the accuracies of the classifications were evaluated.

**Key words:** Hyperspectral data, subpixel classification, Linear Spectral Unmixing, Support Vector Machine, Spectral Angle Mapper

# Obsah

Obsah .....	4
Seznam použitých tabulek a obrázků .....	6
Seznam použitých zkratk .....	8
1 Úvod a cíle práce .....	10
2 Úvod do problematiky a literární rešerše .....	12
2.1 Dálkový průzkum Země .....	12
2.1.1 Spektrální charakteristika vegetace .....	13
2.2 Hyperspektrální data .....	15
2.3 Klasifikace .....	16
2.3.1 Klasifikace vegetace .....	16
2.3.2 Klasifikace druhové skladby .....	17
2.3.3 Subpixelová klasifikace .....	18
2.3.4 Support Vector Machine .....	23
2.3.5 Spectral Angle Mapping .....	25
3 Metodika .....	26
3.1 Zájmové území .....	26
3.2 Použitá data .....	28
3.2.1 Projekt EUFAR .....	29
3.2.2 Letecká data .....	30
3.2.3 Kontaktní sonda .....	30
3.3 Úpravy dat .....	31
3.4 Použitý software .....	33
3.4.1 ENVI .....	33

3.4.2	ArcMap.....	33
3.5	Klasifikace.....	33
3.5.1	Koncové členy.....	34
3.5.2	Linear Spectral Unmixing.....	34
3.5.3	Support Vector Machine .....	35
3.5.4	Spectral Angle Mapping.....	37
4	Výsledky .....	38
4.1	Přesnosti klasifikace .....	38
4.2	Stanoviště .....	39
4.2.1	Alžbětinka .....	40
4.2.2	Pod Lysou horou .....	41
4.2.3	Pod Liščí horou .....	42
4.2.4	Modrý důl.....	44
4.2.5	Pudlava.....	45
4.2.6	Pašerácký chodníček .....	47
4.2.7	Václavák.....	48
4.2.8	Pod Voseckou boudou.....	49
4.3	Porovnání výsledků .....	50
5	Diskuze .....	53
6	Závěr .....	55
	Zdroje.....	57
	Přílohy.....	61



# Seznam použitých tabulek a obrázků

## *Seznam tabulek*

Tab. 1: Elektromagnetické spektrum .....	13
Tab. 2: Použité zkratky stanovišť .....	26
Tab. 3: Korelace mezi spektry z kontaktní sondy a ze snímků APEX .....	32
Tab. 4: Matematická reprezentace kernelových transformací .....	35
Tab. 5: Parametry metody SVM na stanovišti Pod Liščí horou .....	36
Tab. 6: Alžbětinka - přesnosti klasifikace.....	40
Tab. 7: Pod Lysou horou - přesnosti klasifikace.....	42
Tab. 8: Pod Liščí horou - přesnosti klasifikace.....	43
Tab. 9: Modrý důl - přesnosti klasifikace .....	44
Tab. 10: Pudlava - přesnosti klasifikace .....	46
Tab. 11: Pašerácký chodníček - přesnosti klasifikace .....	47
Tab. 12: Václavák - přesnosti klasifikace .....	49
Tab. 13: Pod Voseckou boudou - přesnosti klasifikace.....	50
Tab. 14: Porovnání celkových přesností na jednotlivých stanovištích .....	51
Tab. 15: Porovnání přesností u třídy smrky na jednotlivých stanovištích.....	52
Tab. 16: Stanoviště východ - souřadnice stromů .....	61
Tab. 17: Stanoviště západ - souřadnice stromů .....	62
Tab. 18: Počet trénovacích a kontrolních bodů .....	63

## ***Seznam obrázků***

Obr. 1: Spektrální křivka vegetace.....	15
Obr. 2: Stanoviště - západ.....	27
Obr. 3: Stanoviště - východ .....	28
Obr. 4: Přiřazování pásem APEX a kontaktní sondy.....	31

## Seznam použitých zkratek

APEX	Airborne Prism Experiment – letecký zobrazovací spektrometr
ASTER	Advanced Spaceborne Thermal Emission and Reflection Radiometer – hyperspektrální satelitní senzor
AV ČR	Akademie věd České republiky
AVIRIS	Airborne Visible/Infrared Imaging Spectrometer – letecký obrazový spektrometr měřící v pásmech viditelného a infračerveného spektra
DPZ	Dálkový průzkum Země
FV	fotosyntetizující vegetace (použito u metody výběru koncových členů pomocí AutoMCU)
GPS	Global Positioning System – Globální polohovací systém
GTP	Ground Truth Pixel – vybrané pixely reprezentující reálný krajinný pokryv
IEA	Iterative Error Analysis – Iterativní analýza chyb
KRNAP	Krkonošský národní park
LAI	Leaf Area Index – Index listové plochy
Landsat TM	Landsat Thematic Mapper – satelitní senzor dálkového průzkumu
LSU	Linear Spectral Unmixing – algoritmus subpixelové klasifikace zohledňující směsný obsah pixelu v lineárním poměru
MODIS	Moderate Resolution Imaging Spectroradiometer – obrazový spektrometr středního rozlišení
NDVI	Normalized Difference Vegetation Index – Normalizovaný diferenční vegetační index
NIR	Near Infrared – oblast blízkého infračerveného spektra
NP	národní park

NV	nefotosyntetizující vegetace (použito u metody výběru koncových členů pomocí AutoMCU)
P	půda (použito u metody výběru koncových členů pomocí AutoMCU)
PVI	Perpendicular Vegetation Index – Kolmý vegetační index
ROI	Region of Interests – oblasti zájmu
RBF	Radial Basis Fuction – Radiální bázová funkce
RMS	Root Mean Square – kvadratický průměr
RVI	Ratio Vegetation Index – Poměrový vegetační index
SAM	Spectral Angle Mapper – klasifikace pomocí spektrálních úhlů
SMACC	Sequential Maximum Angle Convex Cone – Sekvenční metoda maximálního úhlu konvexního kužele
SVM	Support Vector Machine – algoritmy podpůrných vektorů
SWIR	Short Waved Infrared – oblast krátkovlnného infračerveného záření
TVI	Transformed Vegetation Index – Transformovaný vegetační index

# 1 Úvod a cíle práce

V poslední době se díky stále větším možnostem rozšiřuje využívání hyperspektrálních dat pro analýzy dálkového průzkumu. Senzory je snímána odrazivost v desítkách až stovkách úzkých spektrálních pásem. Díky tomu je možné z dat získat velmi podrobné informace o zemském povrchu. Pro některé analýzy není dostatečné prostorové rozlišení snímků a je potřeba klasifikovat scénu se subpixelovou přesností.

V předkládané práci bude řešena klasifikace skladby porostů pomocí metod řízené klasifikace, konkrétně Linear Spectral Unmixing, Support Vector Machine a Spectral Angle Mapper v oblastech vnitřních zón Krkonošského národního parku. V zájmové oblasti jsou zejména zóny vzrostlých stromů, odumřelých stromů, nižší porosty a louky. Problém rozlišení jednotlivých druhů vegetace (například borových či smrkových porostů) byl již řešen v jiných pracích s použitím multispektrálních dat či pomocí jiných algoritmů (Dalponte a kol., 2013; Martin a kol., 1998; Middleton a kol., 2003; Sandmeier, Deering, 1999).

Rešeršní část se zaměří na popis jednotlivých metod a konkrétně pak i na variace metody Linear Spectral Unmixing. Jedním ze stěžejních problémů při subpixelové klasifikaci je výběr koncových členů. Zde bude zhodnocena možnost využití dat naměřených při pozemní kampani jako referenčních dat. Nejvhodnější algoritmy budou použity na daných testovacích plochách v Krkonoších. V závěru budou zhodnoceny dosažené přesnosti klasifikace a faktory tuto přesnost ovlivňující.

Metoda Support Vector Machines je metodou strojového učení, která si upraví vstupní prostor tak, aby byla schopna lineárně oddělit jednotlivé třídy pomocí nadrovin. Tato metoda dokáže pracovat s vícedimenzionálními daty a vybrat pásma, která jsou relevantní pro danou klasifikaci (Archibald, Fann, 2007). Při zapojení fuzzy přístupu lze pomocí této metody klasifikovat i na subpixelové úrovni (Bovolo a kol., 2010).

Třetí použitou metodou je Spectral Angle Mapper, který spektrální data ze snímku a z trénovacího souboru převede na vektory do prostoru s počtem dimenzí podle počtu pásem. Algoritmus poté počítá úhel mezi těmito dvěma vektory.

Práce bude řešena za pomoci softwarového nástroje ENVI, který nabízí i algoritmy subpixelové klasifikace hyperspektrálních dat. Hlavním přínosem bude nalezení nejefektivnějšího algoritmu pro klasifikaci jednotlivých druhů porostu, konkrétně smrku ztepilého. Touto problematikou se již dříve zabývaly diplomové práce (Málková, 2010; Zachová, 2011), avšak pouze okrajově a vždy pouze na datech ze Sokolovska. Data nasbíraná v Krkonoších ještě podobným způsobem zpracována nebyla.

Hlavním cílem práce je klasifikace smrkových porostů pomocí metod Linear Spectral Unmixing, Support Vector Machine a Spectral Angle Mapper a zhodnocení přesností těchto přístupů. Dále bude zhodnocena možnost využití spekter naměřených kontaktní sondou při terénní kampani pro extrakci koncových členů pro třídu smrků při subpixelové klasifikaci.

## 2 Úvod do problematiky a literární rešerše

Následující kapitola je úvodem do problematiky řešené v této diplomové práci. Budou zde popsány základní principy dálkového průzkumu Země, dále pak hyperspektrální data a jejich využití při klasifikaci. Následuje část věnovaná samotné klasifikaci vegetace, zejména druhové skladby, a to jak na pixelové, tak na subpixelové úrovni. Jsou zde uvedeny jednotlivé klasifikační metody, které byly v následné práci použity, a jejich dřívější využití v již publikovaných pracích.

### 2.1 Dálkový průzkum Země

Dálkový průzkum Země (DPZ) se zabývá získáváním a následným zpracováním dat o objektech a jevech na Zemi ze zařízení, která nejsou přímo na povrchu Země. Jde tedy o získávání informací o Zemi na dálku bez přímého kontaktu s ní (Čapek, 1988).

Snímkování je založeno na měření intenzity elektromagnetického záření, které je od povrchu odražené, či jím emitované. Pokud senzor snímá pouze přírodní záření (původem ze Slunce), jedná se o pasivní zařízení. Jako aktivní senzory se označují ty, které si jsou schopny zařídit vlastní záření, které vysílají k objektu a zaznamenávají jeho následný odraz od objektu. Aktivní zařízení mají výhodu v tom, že nejsou limitovány oblačností, intenzitou přirozeného záření ani denní dobou. (Čapek, 1988)

Využívané elektromagnetické (EM) záření je tvořeno vlnami, které se skládají ze dvou složek – elektrické a magnetické. Vektory těchto složek jsou na sebe v homogenním izotropním prostředí navzájem kolmé. Rozsah EM záření se popisuje pomocí vlnové délky. To je vzdálenost mezi dvěma vrcholy vlny. Na základě vlnové délky se rozlišují druhy EM spektra (viz Tab. 1). (Kolář a kol., 1997)

Tab. 1: Elektromagnetické spektrum

rozsah vlnové délky	název záření	podrobnější členění
< 0,01 $\mu\text{m}$	gamma a Roentgenovy paprsky	
0,01 - 0,40 $\mu\text{m}$	ultrafialové	
0,40 - 0,70 $\mu\text{m}$	viditelné	fialové 0,4 - 0,45 $\mu\text{m}$
		modré 0,45 - 0,50 $\mu\text{m}$
		zelené 0,50 - 0,58 $\mu\text{m}$
		žluté 0,58 - 0,59 $\mu\text{m}$
		oranžové 0,59 - 0,62 $\mu\text{m}$
		červené 0,62 - 0,70 $\mu\text{m}$
0,70 $\mu\text{m}$ - 1,20 mm	infračervené	blízké 0,70 - 1,40 $\mu\text{m}$
		střední 1,40 - 5,50 $\mu\text{m}$
		vzdálené 5,50 $\mu\text{m}$ - 1 mm
0,10 - 1000,00 cm	mikrovlnné	Ka 0,8 - 1,1 cm
		K 1,1 - 1,7 cm
		Ku 1,7 - 2,4 cm
		X 2,4 - 3,8 cm
		C 3,8 - 7,5 cm
		S 7,5 - 15,0 cm
		L 15,0 - 30,0 cm
		P 30,0 - 100,0 cm
> 1,00 m	radiové	

Zdroj: Čapek, 1988, Kolář a kol. 1997, úpravy autorka

Znalost zářivých vlastností umožňuje z naměřených intenzit záření (příp. emisivity či odrazivosti) určit, o jakou látku se jedná. Zářivé vlastnosti objektu vyjadřuje spektrální charakteristika, která je dána průběhem závislosti odrazivosti či emisivity látky na vlnové délce. Každý materiál má specifický průběh této závislosti, který je vyjádřen pomocí spektrální křivky odrazivosti. (Kolář a kol., 1997)

Odrazivost povrchu je ovlivňována mnoha faktory, patří mezi ně vlivy atmosféry, vlhkost, albedo či intenzita a směr osvětlení. Pro správnou interpretaci snímků dálkového průzkumu Země je důležité znát co nejpodrobněji podmínky, za kterých byla data pořízena.

### 2.1.1 Spektrální charakteristika vegetace

Tato práce se zabývá klasifikací vegetace, a proto je důležité vědět, jak vypadá její typická odrazivost na snímaném spektru. Vegetační spektrální křivka má typický průběh viditelný na Obr. 1. Mezi její nejvýraznější prvky patří „green peak“ (vrchol odrazivosti v zeleném pásmu), „chlorophyll well“ (oblast chlorofylové absorpce), „red-edge“ (prudký nárůst odrazivosti v blízké infračervené části spektra), „NIR plateau“ (oblast vysoké



odrazivosti v blízké infračervené části spektra) a oblasti vodní absorpce. (Varshney, P. K., Arora, M. K., 2004)


Nejvyšší odrazivost ve viditelném spektru je v oblasti zeleného spektra, tedy na vlnových délkách okolo 500 nm, kde se nachází lokální maximum odrazivosti, tzv. „green peak“. Díky tomuto nárůstu se nám vegetace jeví zelená na pohled. V ostatních oblastech viditelného spektra, tedy v modré a červené, je světlo pohlcováno zejména chlorofylem, a tudíž je zde odrazivost velmi nízká. (Varshney, P. K., Arora, M. K., 2004)

Za specifickou je označována zejména oblast nazývaná „red-edge“ nacházející se na vlnových délkách v rozpětí 680 – 750 nm v závislosti na druhu vegetace. Jde o nárůst odrazivosti na hranici mezi oblastí chlorofylové absorpce v červené části spektra a rozptýlu světla na listech v oblasti blízkého infračerveného spektra.

Nejvyšších odrazivostí dosahuje vegetace v oblasti blízkého infračerveného záření (vlnové délky 700 – 1400 nm), kde nacházíme tzv. „NIR plateau“. V regionu středního infračerveného záření se nachází několik výrazných oblastí vodní absorpce (na vlnových délkách okolo 1450, 1950 a 2500 nm).

V oblastech viditelného spektra je odrazivost dána především obsahem a koncentrací fotosyntetizujících pigmentů – konkrétně chlorofylu a, chlorofylu b, xantofylů, anthokyaninu a karotenoidů. V oblastech blízkého infračerveného spektra má největší vliv na odrazivost vnitřní struktura listu, velikost, tvar a rozložení vzduchových bublin, přechody mezi vodou a vzduchem v mezofylu. Ve středním infračerveném spektru hraje hlavní úlohu obsah vody, která zapříčiňuje výrazné oblasti vodní absorpce. V této části spektra mají také vliv biochemické látky, tedy obsah ligninu, celulózy, škrobu, proteinů či dusíku. (Varshney, P. K., Arora, M. K., 2004)

Obr. 1: Spektrální křivka vegetace



Zdroj: Hoffer, 1978, úpravy autorka

## 2.2 Hyperspektrální data

Dříve se používala výhradně multispektrální data, která nesou obrazový záznam ve dvou a více pásmech (maximálně však v řádu desítek) o šířce desítek až stovek nanometrů. Interval y vlnových délek obvykle přibližně odpovídají jednotlivým barvám viditelného spektra nebo vybraným úsekům neviditelné části spektra (infračervené atd.).

V poslední době se začínají prosazovat i hyperspektrální data, která jsou snímána ve více pásmech (v řádu stovek) o šířce 5-10 nm. Pásma na sebe navazují a díky větší podrobnosti lze z těchto dat získat daleko více informací. Kromě rozpoznání pokryvu (les, holá půda, vodní plochy...) jsou možné i daleko podrobnější analýzy (obsah chlorofylu v listech apod.).

## 2.3 Klasifikace

Klasifikace je proces, při kterém se shlukují pixely nebo regiony na snímku do tříd, které se snaží reprezentovat různé fyzikální objekty či typy (Rees, 2001). Rozdělujeme dva typy klasifikačních metod – řízenou a neřízenou.

Řízená klasifikace využívá informací o známém rozložení tříd před zahájením procesu samotné klasifikace. Používá trénovací soubor dat, na kterých se metoda „naučí“, jak mají jednotlivé třídy vypadat. K učení je potřeba mít známá data, používají se například data z pozemních kampaní, měření v laboratořích, map či leteckých snímků. Ve skupině řízených klasifikací lze jako příklad uvést metodu minimální vzdálenosti, metodu maximální věrohodnosti či metodu rovnoběžníků. Do této kategorie spadá i algoritmus Linear Spectral Unmixing či metoda Support Vector Machine.

Algoritmy neřízené klasifikace vyhledávají v datech shluky pixelů s podobnými charakteristikami, spektrálními vlastnostmi (Kolář, 1997). V tomto případě není vyžadována předchozí analýza dat či trénovací soubor. Úroveň úspěšnosti je závislá na spektrálních rozdílech mezi jednotlivými třídami. Neřízená klasifikace tak dokáže odhalit i vzácné třídy, které by nebyly zaznamenány při pozemní kampani. Do této kategorie spadají například algoritmy isodata nebo k-means.

### 2.3.1 Klasifikace vegetace

Rozpoznávání typů povrchu a konkrétně vegetačního pokryvu je jednou ze základních aplikací dálkového průzkumu Země. Odlišit vegetaci od ostatních druhů povrchu na základě spektrálního projevu je dnes běžnou a vcelku jednoduchou úlohou. Problémy nastávají při snahách o rozlišení druhového složení ve zkoumané oblasti. Pro spolehlivější výsledky je stále zapotřebí kombinovat počítačové algoritmy s lidskou interpretací, terénním měřením či topografickými, geologickými nebo geomorfologickými mapami.

#### 2.3.1.1 Vegetační indexy

Vegetační indexy jsou modely, které využívají charakteristické spektrální vlastnosti zelené vegetace na určitých vlnových délkách na vytvoření indexů, které reprezentují například biomasu, vegetační pokryv či změny v něm. Vegetační indexy lze rozdělit do dvou skupin, a to na poměrové a ortogonální (Komeščíková, 2006).

Indexy ze skupiny poměrových dávají do poměru odrazivosti v červené a infračervené oblasti spektra. Sem se řadí například Jednoduchý poměrový vegetační index RVI (Ratio Vegetation Index), Transformovaný vegetační index TVI (Transformed Vegetation Index) či SAVI (Soil Adjusted Vegetation Index), který se snaží o minimalizaci vlivu půdy, je však citlivý na vliv atmosféry. Nejpoužívanějším z této skupiny je Normalizovaný diferenční vegetační index NDVI (Normalized Difference Vegetation Index), který využívá viditelných červených a infračervených pásem multispektrálních dat pro odlišení zelené vegetace od odrazivosti holé půdy (Bean, 2000). Dále se často objevuje Index listové plochy LAI (Leaf Area Index), který udává plochu asimilačního aparátu v metrech čtverečních na 1 m<sup>2</sup> plochy půdy (Schowengerdt, 2007).

Ortogonalní indexy jsou lineární kombinací jednotlivých pásem obrazu. Sem se řadí například PVI (Perpendicular Vegetation Index) odlišující holou půdu od vegetace.

Vegetační indexy jsou však používány zejména pro odlišení a popis celkové plochy vegetace, ne pro klasifikaci jednotlivých druhů stromů.

### **2.3.2 Klasifikace druhové skladby**

Klasifikací jednotlivých rostlinných druhů, převážně stromů, se zabývalo již mnoho prací (Dalponte a kol, 2013; Martin a kol., 1998; Middleton a kol., 2003; Sandmeier, Deering, 1999).

Dalponte a kol. (2013) pracovali s daty ze senzorů HySpex-VNIR 1600 a HySpex-SWIR 320i. Pro zhodnocení možností klasifikace druhů stromů v boreálních lesích vzali v potaz za prvé tři klasifikační metody (SVM, Random Forest a gausovská metoda maximální věrohodnosti), za druhé dvě prostorová rozlišení (0,4 m a 1 m), za třetí dvě sady spektrálních pásem (všechna, nebo jen výběr) a za čtvrté dvě prostorové úrovně (úroveň pixelu a korun stromů). Ke klasifikaci zvolili čtyři třídy: smrk ztepilý, borovice lesní, bříza a listnaté stromy. Výsledky ukázaly, že lepších přesností klasifikace ( $\kappa > 0.8$ ) lze dosáhnout pomocí dat ze senzoru HySpex VNIR 1600, HySpex SWIR 320i má horší výsledky a správně dokáže rozpoznat pouze smrk a borovici. Dále vědci zjistili, že prostorové rozlišení hraje významnou roli v přesnosti klasifikace (pokles o 20 % mezi daty s prostorovým rozlišením 0,4 m a 1,5 m). Mezi metodami SVM a Random Forest nenalezli žádné významné rozdíly.

Martin a kol. (1998) na základě leteckých hyperspektrálních dat rozlišili pomocí algoritmu maximální věrohodnosti 11 typů lesního pokryvu včetně oblastí s čistě jehličnatými stromy, čistě listnatými či smíšeným porostem. Autoři pracovali i s chemickými charakteristikami jednotlivých druhů stromů. Ke zhodnocení přesnosti klasifikace použili data nasbíraná při pozemní kampani. Celková klasifikace náhodně vybraných hodnotících pixelů se pohybovala okolo 75 %.

Middleton a kol. (2003) využili při svém výzkumu a mapování environmentálních dopadů na vegetaci v oblasti mastkových dolů (oblast Lahnaslampi, Finsko) letecká hyperspektrální data ze senzoru HyMap (450 – 2500 nm). Ke klasifikaci a následnému určování její přesnosti dále využili data soupisu lesů, land use, geochemická měření, data o elektrické vodivosti půdy a interpretaci leteckých snímků. Pomocí algoritmu maximální věrohodnosti vyklasifikovali lesní porosty. Vegetační změny mapovali za pomoci vegetačních indexů NDVI a SAVI. Nakonec mapovali rozložení jednotlivých druhů stromů (smrk ztepilý, bříza bělokorá) za pomoci metody maximální věrohodnosti.

### **2.3.3 Subpixelová klasifikace**

Metoda subpixelové klasifikace byla zvolena proto, že je požadována klasifikace jednotlivých druhů stromů, a tudíž nelze předpokládat převážně čisté pixely tvořené pouze jedním druhem porostu. Na subpixelové úrovni lze předpokládat možnost rozlišení druhové skladby porostu do daleko větších podrobností. V literatuře lze najít příklady využití naměřených pozemních dat při klasifikaci druhové skladby (Dalponte a kol., 2012), nikoli však v kombinaci s metodou Linear Spectral Unmixing. Kuběčková (2013) použila tuto metodu pro klasifikaci hornin a smíšených pixelů hornin porostlých lišejníky. Metoda se osvědčila pro vyklasifikování jednotlivých druhů hornin i ze smíšených pixelů, kdy byly horniny porostlé lišejníky. Na základě literatury (Bovolo a kol., 2010; Dalponte a kol., 2013; Kuběčková, 2013; Richter a kol., 2008) byly jako alternativy zvoleny klasifikační metody Support Vector Machine a Spectral Angle Mapper. Výsledky všech přístupů budou následně porovnány.

#### **2.3.3.1 Linear Spectral Mixture Analysis**

Tento přístup je založen na předpokladu, že každý pixel je směsí několika komponent vážených plochou povrchu, kterou zabírají, a spektrum je poté lineární kombinací odrazivosti jednotlivých koncových členů (Bannari a kol., 2006). Teoreticky by tedy bylo

možné rozšifrováním jednotlivých komponent určit všechny druhy povrchu, které se v pixelu nacházejí. Ve skutečnosti je ale problém složitější, protože se zde vyskytuje mnoho dalších faktorů, které ovlivňují naměřené hodnoty senzoru. Mezi tyto faktory patří například efekty atmosféry, šum senzoru, sklony svahů terénu, hrubost povrchu a další radiometrické vlivy (Neville a kol., 1999).

Vztah pro lineární spektrální analýzu je možno zapsat pomocí vzorce

$$R_b = \sum_{i=1}^m f_i r_{bi} + e_b,$$

kde

$$\sum_{i=1}^m f_i = 1.0,$$

$R_b$  je odrazivost pixelu v pásmu  $b$ ,  $f_i$  je poměrná část (fractional abundance) koncového členu  $i$ ,  $m$  značí celkový počet koncových členů,  $r_{bi}$  je odrazivost v pásmu  $b$  koncového členu  $i$  a  $e_b$  je residuum (zbytková chyba) v pásmu  $b$ . (Bannari a kol., 2006).

### 2.3.3.2 Výběr koncových členů

Koncové členy reprezentují jednotlivé materiály na snímku, jejich odrazivost v čisté podobě. Jejich získání je pro metodu linear unmixing klíčové. Je potřeba mít koncový člen každé části povrchu ve scéně obsažené. Na základě předpokladů, že odrazivost jednoho pixelu je sumou odrazivostí jednotlivých koncových členů a že tato spektra jsou lineárně nezávislá, lze zjistit konkrétní složení materiálů ve scéně na základě výpočtu kombinace spekter koncových členů, které se podílely na výsledné odrazivosti (Neville a kol., 1999).

Hodnoty odrazivosti koncových členů je možno přebrat z knihoven spektrálních odrazivostí povrchů. Tyto hodnoty jsou ale v naprosté většině případů měřeny za jiných vnějších podmínek než data, která máme k dispozici. Druhou možností je měřit přímo ve snímku pomocí manuálního vyhledání čistých pixelů (tzn., že jeden materiál zabírá celý pixel). Třetím řešením je mít hodnoty odrazivosti naměřené přímo v terénu v čase, kdy probíhalo samotné snímkování oblasti.

Vzhledem k tomu, že zdaleka ne vždy je možné sbírat data o odrazivosti jednotlivých povrchů přímo v terénu zároveň s dálkovým snímáním a manuální extrakce koncových

členů je značně zdlouhavá a náročná, zkoumají se zejména automatické metody, které jsou schopné na snímcích nalézt jednotlivé koncové členy.

Výběr koncových členů je při subpixelové klasifikaci stěžejním problémem. V literatuře je popsáno mnoho způsobů, jak čisté pixely extrahovat ze souboru dat. Neville a kol. (1999) použili algoritmus iterativní analýzy chyb, Bannari a kol. (2006) využili manuální extrakci, Asner a Heidebrecht (2002) přišli s plně automatickým modelem AutoMCU, který je založen na přístupu Monte Carlo.

### ***Iterativní analýza chyb (Iterative Error Analysis)***

Neville, R. A. a kol. (1999) zkoumali automatickou metodou výběru koncových členů Iterative Error Analysis (IEA). Při metodě je použit algoritmus, který provádí sérii jednotlivých linear unmixing, využívající jako koncový člen vždy ty pixely, které minimalizují zbývající chybu ve snímku, do té doby, než dosáhne ukončující podmínky. Tou je zpravidla dosažení předem určeného počtu koncových členů, nebo předdefinované dostatečně malé chyby. Tuto metodu lze použít přímo na spektrální data, nevyžaduje transformaci na hlavní komponenty či jinou transformaci spektrálního prostoru.

Pro start algoritmu je potřeba vypočítat počáteční vektor, který se pokládá jako průměrné spektrum použitých dat. Po první iteraci linear unmixing s tímto vektorem je vytvořen chybový snímek, což je matice zbytkových chyb pro jednotlivé pixely. Vektory, které jsou od průměrného spektra nejdále (na základě euklidovské vzdálenosti), vykazují největší chybu. Dá se předpokládat, že tyto vektory leží na místech styku shluků dat, takže reprezentují relativně čisté pixely. Průměr hodnot těchto pixelů je poté použit jako první koncový člen. Průměr se používá proto, aby se omezily vlivy odlehlých pixelů a šumu. Nyní se provede další linear unmixing s použitím prvního koncového členu a vektory nejdále od prvního koncového členu, které mají největší chybu. Tyto vektory se opět zprůměrují a vytvoří tak druhý koncový člen. Celý proces se opakuje až do té doby, než je chyba metody menší než zvolená prahová hodnota, nebo je dosaženo předem definovaného počtu koncových členů.

Richter a kol. (2008) využívají stejnou metodu, ale na předem zpracovaných datech. Nejprve odfiltrovali vodní plochy pomocí klasifikátoru parallelepiped a data normalizovali, aby zabránili vlivu různé jasnosti pixelů na IEA.

U metody byla prokázána její robustnost (Neville a kol., 1999). Další výhodou je, že koncovým členům je automaticky přiřazována priorita. Pořadí, ve kterém jsou koncové členy extrahovány přímo, souvisí s požadovanou minimální chybou.

### ***Manuální extrakce***

Pro použití manuální extrakce koncových členů se předpokládá dobrá předchozí znalost snímkaného terénu. Tuto metodu využil například Bannari a kol. (2006) při mapování zbytkového pokryvu po sklizni. Koncové členy vybírali autoři studie v setech dat z Probe-1 i IKONOS. Pro každý povrch, který chtěli následně klasifikovat, vybrali tři čisté pixely jako koncové členy. Autoři studie měli ale předem vybraná místa snímkování na testovací farmě v Saskatchewanu, kde na každém poli měli jasně definované plochy 20 x 20 m s každým potřebným povrchem. Takové podmínky jsou však spíše výjimečné.

### ***AutoMCU***

Asner a Heidebrecht (2002) přišli s plně automatickým modelem, který využívá přístupu Monte Carlo a je založen na algoritmu původně vyvinutém pouze pro krátkovlnná infračervená spektra. Autoři metodu vyzkoušeli na klasifikaci tří povrchů – fotosyntetizující vegetace (FV), nefotosyntetizující vegetace (NV) a holá půda (P).

Auto MCU využívá tři „svazky“ spektrálních koncových členů (FV, NV, P) pocházející z terénního měření pro rozložení každého pixelu za pomoci rovnice, která předpokládá, že jednotlivé pixely jsou složeny z lineární kombinace jednotlivých koncových členů:

$$\rho(\lambda)_{pixel} = \sum_{k \in \{FV, NV, P\}} C_k \rho(\lambda)_k = C_{FV} \rho(\lambda)_{FV} + C_P \rho(\lambda)_P + C_{NV} \rho(\lambda)_{NV},$$

kde  $\rho(\lambda)_k$  značí odrazivost každého koncového členu  $k$  půdního pokryvu na vlnové délce  $\lambda$  a  $C_k$  představuje část subpixelového pokryvu (pro každý koncový člen půdního pokryvu může být vyplněna fotosyntetizující vegetací, nefotosyntetizující vegetací, holou půdou, nebo třídou ostatní). K vypočítání jednotlivých částí subpixelového pokryvu je potřeba mít dostatek pozorování, aby obsahovala potřebné informace k vyřešení soustavy lineárních rovnic, tedy každou formu rovnice výše popsání, ale pro různé vlnové délky.

Výsledky Monte Carlo spektrálního rozložení byly ve studii Asnera a Heidebrechta (2002) dva: jednak přesnost odhadů FV, NV a P, jednak nejistota těchto odhadů. Autoři obě tyto hodnoty porovnávali u spectral unmixing analýzy dat ze spektrometrů AVIRIS,



Landsat TM, MODIS a ASTER. Srovnání jasně ukázalo omezení v užití plného optického rozsahu spektra (400 – 2500 nm) nebo i části viditelné-NIR (400 – 1300 nm) pro dekompozici pixelů snímku na části pokryté FV, NV a P v suchých travnatých oblastech a buši. Měření v krátkovlnné infračervené části spektra (2000 – 2300 nm) vykazala výrazné rozdíly ve spektrálních projevech FV, NV, P. Nejpřesnější odhady koncových členů FV, NV a P v aridních oblastech byly prokázány, když byla data naměřená v oblasti SWIR normalizována pomocí hodnoty 2030 nm. Vhodná data pro tuto analýzu byla získána ze senzoru AVIRIS.

### ***SMACC***

Gruninger a kol. (2004) představili metodu Sequential maximum angle convex cone (sekvenční metoda maximálního úhlu konvexního kužele) pro výběr koncových členů přímo ze snímku. Algoritmus nalezne extrémní vektory v datech. Ty jsou definované jako vektory, které nemohou být reprezentovány pomocí pozitivní lineární kombinace jiných vektorů ve snímku. Tímto způsobem nalezené vektory položí jako koncové členy. Tyto koncové členy vytvoří konvexní kužel, ve kterém jsou ostatní neextrémní vektory, tedy takové, které lze modelovat jako pozitivní lineární kombinaci extrémních vektorů. Metoda je sekvenční, v každém cyklu se formuje nový konvexní kužel tak, že se vybere vektor, který leží nejdále od základny již existujícího kužele, kam se následně přidá.

Autoři (Gruninger a kol., 2004) aplikovali tuto metodu na data ze senzoru AVIRIS. Osvědčilo se jim použití na hyperspektrálních datech, kde metoda nalezne malé soubory koncových členů, které reprezentují jednotlivé typy materiálů a jejich varianty. Pokud se algoritmus aplikuje na snímky, dokáže extrahovat spektrální pásma, kde jsou snímky vysoce korelované. Tak se dají odlišit pásma, ve kterých jsou snímky téměř stejné od těch, která přinesou novou spektrální informaci.

#### **2.3.3.3 Algoritmy Linear Spectral Unmixing**

Podle Averbucha a Zheludeva (2012) lze algoritmy linear spectral unmixing rozdělit do několika skupin podle převládajících trendů v jejich zpracování.

##### ***Lineární přístup***

Při modelu linear mixing se známým počtem koncových členů a jejich spektrálních charakteristik, se stává z rozkódování složek pixelů hyperspektrálních snímků lineární problém, na jehož vyřešení je možné použít například metodu nejmenších čtverců. Tato

metoda ale nedodává dostatečně přesné odhady a nedokáže kvalitně popsat fyzikální charakter snímkaného povrchu. Rozdíl mezi různými spektry materiálů je podmíněn převážně rozdílem v chování jejich prvních a druhých derivací, ne trendem.

### ***Analýza nezávislých komponent***

Analýza nezávislých komponent je metoda založená na separaci signálu na doplňující se dílčí komponenty za předpokladu statistické nezávislosti složek. Bylo prokázáno, že tato metoda není vhodná pro práci s hyperspektrálními daty (Averbuch, Zheludev, 2012).

### ***Geometrický přístup***

Tento přístup na každý pixel pohlíží jako na vektor v L-dimenzionálním euklidiánském prostoru (kde L značí počet pásem) a každý kanál odpovídá jedné ose. Na hyperspektrálních datech se využívá tento přístup v algoritmech MVT (minimum volume transform) či PPI (pixel purity index).

### ***Extending subspace approach***

Jedním z algoritmů tohoto přístupu je analýza vrcholových komponent (vertex component analysis, VCA). Metoda vychází ze dvou předpokladů: 1. Koncové členy jsou vrcholy simplexu. 2. Afinní transformací simplexu vznikne zase simplex. Předpokladem jsou také čisté pixely v datech. Algoritmus iterativně promítá data na kolmici k již existujícímu subprostoru vymezenému již detekovanými koncovými členy, dokud nenajde všechny koncové členy. Tento postup je spolehlivý, ale také velmi výpočetně náročný.

## **2.3.4 Support Vector Machine**

Support Vector Machine (SVM, mechanismus podpůrných vektorů) je metoda klasifikace na základě strojového učení. Byla u ní zjištěna vyšší klasifikační přesnost než u dalších metod rozpoznávání obrazu, jako jsou metoda maximální věrohodnosti (maximum likelihood) nebo klasifikátory založené na neuronových sítích. Tato metoda se také prokázala jako výhodná pro příklady, ve kterých je k dispozici více heterogenních tříd s omezeným počtem trénovacích vzorků. (Melgani, F., Bruzzone, L., 2004)

Metoda se natrénuje na souboru dat, na základě kterého se snaží proložit souborem klasifikovaných dat nadplochu tak, aby data rozdělila do dvou skupin na základě maximalizace vzdálenosti mezi nejbližším trénovacím vzorkem a nadplochou. Metodu je možné modifikovat tak, aby se data nelineárně transformovala do vyšší dimenze, a lineární

nadplochu prokládá až pak (Melgani, F., Bruzzone, L., 2004). Metoda je tedy schopná převést úlohu lineárně neseparabilní na úlohu lineárně separabilní (Dorič, 2013). Pokud je nutné data transformovat do vyšších dimenzí, je potřeba mít větší trénovací soubor.

V případě 2D dat (tedy například bodů, které mají hodnotu vlnové délky na ose x a odrazivosti na ose y) metoda prokládá na základě trénovacího souboru přímku tak, aby eukleidovská vzdálenost nejbližších dat z různých tříd k dělicí přímce byla co největší.

Jde o metodu binární, tedy odděluje od sebe jen dvě třídy, ale existuje několik přístupů, jak lze za pomoci SVM klasifikovat i více tříd. Melgani a Bruzzone (2004) ve své práci uvádí čtyři rozdílné strategie, jak různé kombinace a úpravy metody SVM použít pro klasifikaci hyperspektrálních dat na více než dvě třídy. Základem jsou dva kroky – definice souboru binárních klasifikátorů a jejich kombinace na základě určitých rozhodovacích pravidel. První krok obsahuje definování jednotlivých problémů vždy po dvou třídách. Následně autoři rozlišují dva přístupy k řešení problému, a to za prvé přístup paralelní a za druhé přístup založený na hierarchickém stromu.

### ***Paralelní přístup (Parallel Approach)***

#### **a) Strategie Jeden proti všem (One-Against-All Strategy – OAA)**

Jde o nejstarší a nejpoužívanější přístup ke klasifikaci více tříd ( $n > 2$ ) pomocí SVM. Jedná se o paralelní architekturu sestavenou z  $n$  počtu SVM, jednu pro každou třídu. Každá z nich řeší svůj problém dvou tříd definovaný jako jedna třída proti všemu ostatnímu.

#### **b) Strategie Jeden proti jednomu (One-Against-One-Strategy - OAO)**

Tato strategie obsahuje  $\frac{n(n-1)}{2}$  SVM. Tento model postihuje všechny možné páry klasifikací. Každá SVM zde provede klasifikaci, kde jsou proti sobě postaveny vždy dvě třídy.

### ***Přístup založený na hierarchickém stromu (Hierarchical Tree-Based Approach)***

#### **a) Strategie binárního stromu s vyrovnanými větvemi (Binary Hierarchical Tree – Balanced Branches Strategy BHT – BB)**

Rozhodovací strom je v této strategii definován tak, že každý uzel je reprezentovaný metodou SVM mezi dvěma skupinami tříd se stejnými předchozími kumulativními pravděpodobnostmi.

- b) Strategie binárního stromu jeden proti všem (Binary Hierarchical Tree – One Against All Strategy = BHT – OAA)

Tato strategie zjednodušuje OAA strategii pomocí její implementace do hierarchického kontextu. Každý uzel zde rozhoduje mezi dvěma skupinami tříd A a B, kde třída B reprezentuje informační třídu s nejvyšší předchozí pravděpodobností z těch, co spadají do sjednocení A a B. Tento typ hierarchie vede ke stromu s pouze jednou větví.

### 2.3.5 Spectral Angle Mapping

Spectral Angle Mapping (klasifikace pomocí spektrálních úhlů) je automatická metoda, která porovnává spektra ze snímku se spektry z knihovny či z kontaktního měření. Předpokládá, že data byla upravena na zdánlivou zář, což je skutečná odrazivost znásobená faktorem na základě topografie a zastínění území. Pro každý pixel si vezme obě spektra a převede je na vektory do prostoru s počtem dimenzí podle počtu pásem. Algoritmus pak určuje podobnost mezi dvěma spektry na základě vypočtení spektrálního úhlu mezi těmito vektory. Vzhledem k tomu, že metoda pracuje pouze se směrem, nikoli délkou vektoru, je nezávislá na faktoru, kterým se data násobí, a tudíž i na osvětlení jednotlivých pixelů. (ENVI, 2004)

Při klasifikaci hyperspektrálních snímků je spektrální úhel vypočítán pro každý pixel. Výsledek v radiánech je přiřazen danému pixelu a tímto způsobem je vytvořena maska pro každé referenční spektrum. Tímto způsobem vznikne nová datová kostka s počtem pásem rovnajícím se počtu použitých referenčních pásem. (ENVI, 2004)

## 3 Metodika

Tato kapitola obsahuje popis řešeného území, použitých dat a metod klasifikace, které byly při práci využity. Dále jsou zde popsány úpravy, které byly s daty provedeny před spuštěním klasifikací. Kapitola 3.4 se věnuje softwarovým nástrojům, ve kterých byla data zpracovávána.


### 3.1 Zájmové území

Řešené území se nachází v oblasti vnitřních zón Krkonošského národního parku na dvou lokalitách – východní a západní. V obou oblastech jsou vždy čtyři stanoviště, kde se sbíraly vzorky větví stromů pro další zpracování. Pro jednotlivá stanoviště budou v dalším textu a tabulkách použity zkratky, které jsou shrnuté v Tab. 2.

Tab. 2: Použité zkratky stanovišť

	stanoviště	zkratka
západ	Alžbětinka	A
	Pod Lysou horou	LH
	Pod Voseckou boudou	VB
	Pudlava	P
východ	Modrý důl	MD
	Pašerácký chodníček	PA
	Pod Liščí horou	LI
	Václavák	V

Obr. 2: Stanoviště - západ



Západní část je v oblasti mezi Harrachovem, Rokytnicí nad Jizerou a Špindlerovým Mlýnem. Stanoviště Pod Voseckou boudou se nachází na stráni Tvarožníku pod Voseckou boudou. Stanoviště Alžbětinka a Pod Lysou horou jsou na severním svahu Lysé hory, jižně (LH) a jihovýchodně (A) od turistického rozcestí Krakonošova snídane. Stanoviště Pudlava se nachází v Pudlavském dole.

Obr. 3: Stanoviště - východ



Východní lokalita se nachází v okruhu okolo Pece pod Sněžkou a Velké Úpy. Stanoviště Pašerácký chodníček leží na jižním svahu Svorové hory. Stanoviště Modrý důl je v Modrém dole mezi Studničním potokem a Studničními boudami. Stanoviště Pod Liščí horou se nachází na svazích Liščí hory severozápadě od Liščí louky. Stanoviště Václavák leží na severním svahu Černé hory v blízkosti Černoohorského rašeliniště.

### 3.2 Použitá data

Data z oblasti Krkonošského národního parku byla pořízena v červnu 2012. Proběhlo letecké snímkování a terénní kampaň, při které se nasbíraly vzorky z osmi vybraných stanovišť. Jednotlivé lokality byly vybrány jako reprezentativní vzorky vegetačního pokryvu v dané oblasti za spolupráce zaměstnanců Krkonošského národního parku, doc. RNDr. Pavla Cudlína, CSc. z CZECHGLOBE (Centrum výzkumu globální změny AV ČR) a odborníků z katedry experimentální biologie rostlin. Každý strom vybraný pro analýzu byl zaměřen pomocí GPS s přesností od 20 cm do 6 m. (Suchá, 2013)

Na každé lokalitě bylo vybráno pět stromů, ze kterých se odebraly živé vzorky pro následné měření v laboratoři. Větve se odebíraly z produkční části koruny tak, aby z každého stromu byl vzorek jehlic z výše položených větví (z přechodu juvenilní a produkční části koruny) a z větví rostoucích níže. Pomocí kontaktní sondy byly naměřeny hodnoty spektrální odrazivosti pro jehlice z horních i spodních větví se stářím dva a tři roky. Pro měření spekter byl využit spektrometr ASD FieldSpec 4 Wide-Res s připojenou kontaktní sondou. Výsledky se zpracovávaly v programu se softwarem RS3m, ve kterém lze nastavovat parametry měření sondou jako například čas jednoho měření, jak se bude průměrovat výsledná křivka pro jednotlivé vzorky a podobně. Před měřením je vždy potřeba provést kalibraci světelných podmínek, která se provádí na bílém terči. Z každého vzorku se odebere několik větviček s jehlicemi, které se v co nejsouvislejší vrstvě pokladou na černou skleněnou misku. Následně je přiložena kontaktní sonda a uložena spektrální křivka vygenerovaná pro dané měření. Pro každý vzorek bylo provedeno pět měření na různých místech poskládaných jehlic. Z daných pěti měření byly vytvořeny průměry, které pak v dalším zpracování reprezentovaly hodnotu pro daný vzorek. (Suchá, 2013)

Následně byly vytvořeny průměry pro skupiny horních a dolních, dvouletých a tříletých větví pro každé stanoviště. Tyto statistiky jsou přiloženy na CD.

### **3.2.1 Projekt EUFAR**

Data použitá v této diplomové práci byla pořízena v rámci vědeckého mezinárodního projektu HyMountEcos, který se zabývá hyperspektrálním dálkovým průzkumem horských ekosystémů. Jeho cílem je monitoring vysoce hodnotných ekosystémů pohoří Krkonoše na obou stranách česko-polské hranice za pomoci spojení dat z leteckého snímkování a terénních kampaní. Na projektu spolupracují vědečtí pracovníci z polské Uniwersytet Warszawski a z Přírodovědecké fakulty Univerzity Karlovy za podpory správy krkonošských národních parků obou zemí. V Polsku se jedná o první hyperspektrální snímání od roku 2002, v Česku se hyperspektrální data sbírala například v oblasti Sokolovské pánve v rámci projektu HypSo či v NP Šumava. Jde o první letecké hyperspektrální snímání oblasti biosférické rezervace Krkonoše rozprostírající se na obou stranách hranice na ploše 60 362 ha.

Aby bylo možné zachytit přírodní bohatství a aby měli možnost analyzovat biodiverzitu oblasti, navrhli řešitelé snímat území od nejnižších nadmořských výšek v



podhorském pásu po oblasti alpinského pásu v obou státech. Tímto postupem byla zajištěna variabilita vegetačního pokryvu i pigmentu listoví a zároveň je možné porovnávat ekosystémy na české a polské straně. Vybrány byly dvě výzkumné oblasti – západní a východní. Na východě jde o území, které je velmi hodnotné svými různorodými ekosystémy. Západní oblast naproti tomu byla v minulosti nejvíce poškozena vlivy znečištění ovzduší a lesní ekosystémy ani půda se z těchto negativních změn ještě nedokázaly plně zotavit. Tímto přístupem byly pokryty jak co se přírodní diverzity týče, nejhodnotnější oblasti biosférické rezervace Krkonoše, tak části nejvíce zatížené znečištěním. Díky tomu jde o data s vysokým informačním potenciálem a širokými možnostmi pro řešitele projektu. (Transnational Access project HyMountEcos, 2012)

Zároveň s leteckým snímkováním proběhla pozemní kampaň, při které výzkumníci měřili spektra vegetace z oblastí konkrétních ekosystémů, probíhala spektrální měření nerostů, hornin a půdy a sbíraly se vzorky vegetace a půd pro následné zpracovávání v laboratořích.

### **3.2.2 Letecká data**

Letecká data byla nasnímána senzorem APEX z paluby letadla DO228/D-CODE-DLR dne 10. září 2012 v čase 10:35 až 14:13. Data celkem v patnácti letových liniích byla snímána z letových výšek 5 750 m a 6 065 m (Suchá, 2013). Pořízené snímky mají prostorové rozlišení 2 m. Senzor snímá hodnoty odrazivosti na 316 vlnových délkách, ve snímcích se objevuje 288 pásem.

Pro Českou republiku bylo pořízeno sedm letových linií. Na snímcích byly provedeny radiometrické, atmosférické a geometrické korekce. Ty byly zpracovány v německém Oberpfaffenhofenu na pracovišti Deutsches Zentrum für Luft und Raumfahrt e. V.. (Suchá, 2013)

### **3.2.3 Kontaktní sonda**

Vzorky větví sesbíraných při pozemní kampani byly zpracovány pomocí přístroje ASD FieldSpec 4 Wide-Res s připojenou kontaktní sondou. Zařízení je produktem firmy Analytical Spectral Devices, Inc. (ASD) ze Spojených států. Přístroj je schopen měřit na spektru od 350 nm do 2 500 nm s vylepšeními v oblastech SWIR, která umožňují zpracovávat data rychleji se zachováním stejné kvality jako u předchozích modelů.

Zachycuje spektra s rozlišením 30 nm. Optickým kabelem lze přístroj připojit přímo k počítači, kde lze naměřená spektra ukládat a následně dále zpracovávat.


### 3.3 Úpravy dat

Před samotnou klasifikací bylo zapotřebí získaná data zkalibrovat a upravit pro další použití. Některé úpravy leteckých dat byly provedeny již před zveřejněním dat pořizovatelem, zbytek pak autorkou.

Ze spekter naměřených pro jednotlivé vzorky byly vytvořeny průměry pro každý strom, pro horní větev, dolní větev, dvouleté a tříleté vzorky.

Průměrné hodnoty odrazivosti pro jednotlivé vlnové délky naměřené kontaktní sondou bylo potřeba přiřadit k datům leteckého snímkování. Na základě popisu jednotlivých pásem APEX byla vybrána jasně přiřaditelná dvojice vlnové délky z kontaktní sondy a pásma snímku ze senzoru APEX (viz ilustrační Obr. 4). Kontaktní sonda snímala odrazivost vzorku na každé vlnové délce od 350 do 2 500 nm s intervalem 1 nm, senzor APEX oproti tomu nesnímal odrazivost do jednotlivých pásem na vlnových délkách, která by se dala vyjádřit celým číslem. Aby bylo možné porovnávat odrazivosti na určité vlnové délce, byla vybrána taková pásma APEX, jejichž hodnoty vlnové délky byly porovnatelné s vlnovou délkou z kontaktní sondy, tj. akceptovatelný rozdíl vlnových délek byl menší než 0,4 nm. Vlnové délky, ke kterým by nebylo možné přiřadit jednoznačně pásmo APEX, byly vyřazeny (na Obr. 4 znázorněny prázdným kolečkem). Po těchto úpravách bylo možné porovnávat data pozemní a letecká.

Obr. 4: Přiřazování pásem APEX a kontaktní sondy



Pomocí Pearsonova korelačního koeficientu bylo zkontrolováno, že data jsou porovnatelná. Koeficient se vypočítá pomocí rovnice (Stangroom, J., 2014):

$$\rho_{x,y} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}}$$

Proměnné  $x$  a  $y$  zde značí soubor odrazivostí pro jednotlivé vlnové délky pro jednotlivé stromy naměřené na snímcích a pomocí kontaktní sondy,  $\bar{x}$  a  $\bar{y}$  jsou průměry těchto souborů.

U všech stromů korelační koeficient při porovnání dat z kontaktní sondy a z leteckého snímkování překročil hodnotu 0,90 (konkrétně se hodnoty pohybovaly v rozmezí 0,905 na vzorku P-P2 a 0,991 na vzorku LI-81), která indikuje velmi vysokou závislost mezi těmito soubory.

Hodnoty korelace mezi daty z kontaktní sondy a z leteckého snímkování jsou uvedeny v následující tabulce:

Tab. 3: Korelace mezi spektry z kontaktní sondy a ze snímků APEX

stanoviště	Alžbětinka				
vzorek	A-C11	A-C12	A-F2	A-F3	A-F4
korelační koeficient	0,979	0,920	0,963	0,989	0,971
stanoviště	Pod Lysou horou				
vzorek	LH-28	LH-33	LH-37	LH-39	LH-58
korelační koeficient	0,984	0,976	0,983	0,977	0,967
stanoviště	Pod Liší horou				
vzorek	LI-52	LI-56	LI-81	LI-91	LI-102
korelační koeficient	0,967	0,935	0,991	0,968	0,957
stanoviště	Modrý důl				
vzorek	MD-A	MD-B	MD-F	MD-H	MD-K
korelační koeficient	0,980	0,986	0,986	0,976	0,980
stanoviště	Pudlava				
vzorek	P-P1	P-P2	P-P3	P-P4	P-P5
korelační koeficient	0,946	0,905	0,956	0,945	0,961
stanoviště	Pašerácký chodníček				
vzorek	PA-C1	PA-C7	PA-E1	PA-E8	PA-E10
korelační koeficient	0,971	0,962	0,968	0,969	0,959
stanoviště	Václavák				
vzorek	V-44	V-91	V-93	V-146	
korelační koeficient	0,965	0,971	0,972	0,960	
stanoviště	Pod Voseckou boudou				
vzorek	VB-14	VB-24	VB-27	VB-45	VB-47
korelační koeficient	0,966	0,961	0,976	0,949	0,964

U každého stromu byla provedena korelace mezi spektry ze snímku a z kontaktní sondy. Z pásem, ve kterých byly porovnatelné vlnové délky (tedy vlnová délka v pásmu APEX odpovídala vlnové délce, na které měřila kontaktní sonda), bylo vybráno 164 takových, kde korelační koeficient překročil hodnotu 0,999. U takovýchto pásem lze předpokládat, že koncové členy, které byly naměřeny v laboratoři, budou vhodné pro klasifikaci ve snímku, protože je mezi pásmy vysoká míra korelace mezi hodnotami odrazivosti ve snímku a naměřenými pomocí kontaktní sondy.

### **3.4 Použitý software**

Při zpracovávání této diplomové práce byl využit program ENVI na zpracování klasifikací hyperspektrálních dat a program ArcMap pro tvorbu kartografických výstupů.

#### **3.4.1 ENVI**

ENVI je softwarový balík od firmy Exelis vytvořený pro vizualizaci, analýzu a prezentaci digitálních snímků, který obsahuje nástroje pro geometrickou korekci, terénní analýzy, práci s rastrovým i vektorovým formátem dat, spektrální analýzy atd. V programu nejsou žádná omezení na počet zpracovávaných pásem, tudíž je možné ho použít pro práci jak s multispektrálními, tak i hyperspektrálními daty. (ENVI, 2004)

Program ENVI je napsán v IDL (Interactive Data Language). Jde o strukturovaný programovací jazyk, který umožňuje zpracování snímků.

#### **3.4.2 ArcMap**

ArcMap je základní aplikací ze souboru programů ArcGIS od firmy Esri. Je určen k prohlížení, tvorbě, editaci a analýzám prostorových dat. Kartografické výstupy pro předkládanou diplomovou práci byly vytvořeny ve verzi ArcMap 10.2.

### **3.5 Klasifikace**

V práci bylo použito několik metod subpixelové řízené klasifikace. Tyto metody byly vybrány na základě literární rešerše tak, aby s jejich pomocí bylo možno dosáhnout cílů práce.

Všechny klasifikace byly prováděny v softwaru ENVI, ve kterém jsou použité metody implementovány i s některými přidruženými nástroji. Navíc software umožňuje volné nastavování parametrů dle potřeb uživatele.

### 3.5.1 Koncové členy

Pro řízenou klasifikaci, či učící algoritmy jsou tzv. koncové členy, tedy čisté pixely obsahující jeden druh povrchu, naprosto klíčové. Na jejich základě algoritmus klasifikuje celou scénu. Pokud klasifikátor musí rozpoznat jednotlivé druhy povrchu i na úrovni nižší než pixel, potřeba čistých pixelů bez jiných příměsí ještě vzrůstá. K tomuto účelu byly využity jednotlivé stromy, které byly zaměřeny přímo v terénu a které jsou prokazatelně smrky.

Ve snímku byly na základě zaměřených stromů a naměřených hodnot odrazivosti pro jehlice smrku identifikovány ROI (z angl. Region of Interest – oblasti zájmu) v podobě jednotlivých pixelů. Soubor těchto koncových členů byl použit pro klasifikaci pomocí jednotlivých metod.

### 3.5.2 Linear Spectral Unmixing

Metoda Linear Spectral Unmixing je obsažena v softwarovém balíku ENVI. Zásadním krokem je zadání koncových členů, protože od čistoty koncových členů se odvíjí přesnost klasifikace. V ideálním případě by mělo jít o pixely složené čistě z jednoho materiálu bez jiných příměsí. V případě této diplomové práce byly použity jako základní koncové členy stromy zaměřené v terénu, respektive pixely, na kterých se tyto stromy nacházely ve výřezu snímku. Porovnáváním spektrálních charakteristik v jednotlivých pásmech byly vybrány další reprezentativní pixely, na jejichž základě byla vyklasifikována třída smrků. V případě ostatních tříd nebyly k dispozici konkrétní změřené pixely, a tak bylo potřeba koncové členy hledat na základě jiných kritérií. Ve snímku byly nalezeny vzorky jednotlivých povrchů a na základě jejich spektrálních charakteristik následně vytvořeny soubory koncových členů.

Jediným dalším parametrem je „unit sum constraint“, ve kterém lze nastavit váhy do klasifikačních rovnic, aby jejich součet byl roven jedné. Výsledkem z  $n$  počtu koncových členů je  $n + 1$  počet pásem klasifikovaného snímku. Pro každé klasifikační pravidlo je vytvořena matice s hodnotami pixelů, které odpovídají části, kterou zaujímá

materiál daného koncového členu v daném pixelu. Jedno pásmo navíc je vyhrazeno pro hodnoty RMS daného pixelu, ze kterých se dá zjistit, ve které oblasti měl klasifikátor problém, jaké koncové členy byly nedostatečně definovány, či chybí. (ENVI, 2004)

Pro vytvoření barevné syntézy se používá Rule Image Classifier, ve kterém se každému pásmu nastaví práh, od kterého se ve výsledném snímku zobrazí. Pro každé pásmo lze práh určovat podle histogramu hodnot daného pásma.

### 3.5.3 Support Vector Machine

Tato metoda je také implementována přímo v softwarovém balíku ENVI. Zde je možno nastavit několik parametrů, a tím přizpůsobit klasifikaci na míru používaným datům. Nejprve je opět potřeba zadat velikost snímku či výřezu, který bude zpracovávat, a pásma, ze kterých se vytvoří příznakový prostor. Důležitý je zde soubor koncových členů, na jejichž základě se budou třídy (resp. třída) rozpoznávat.

Následně se otevře okno s dalšími možnostmi nastavení. Důležitá je volba jádrové (kernelové) transformace prostoru příznaků. Tato funkce slouží k transformaci lineárně neseparovatelné úlohy na lineárně separovatelnou při hledání dělící nadroviny, tedy o posun do vyšší dimenze v příznakovém prostoru. Program ENVI nabízí čtyři typy kernelové transformace, a to lineární, polynomiální, RBF (Radial Basis Function) a sigmoidní. V tabulce Tab. 4 jsou uvedeny předpisy jádrových funkcí  $K$  na datech v původním prostoru parametrů pro jednotlivé transformace.

Tab. 4: Matematická reprezentace kernelových transformací

transformace	matematický vzorec	gamma
lineární	$K(x_i, x_j) = x_i^T x_j$	
polynomiální	$K(x_i, x_j) = (\gamma x_i^T x_j + r)^d$	$\gamma > 0$
RBF	$K(x_i, x_j) = \exp(-\gamma \ x_i - x_j\ ^2)$	$\gamma > 0$
sigmoidní	$K(x_i, x_j) = \tanh(\gamma x_i^T x_j + r)$	

Zdroj: ENVI Help, 2014

Parametr  $\gamma$  definuje, jak širokou má působnost každý samostatný trénovací příklad. Pokud je parametr nižší, klasifikátor se pohybuje ve větším okruhu kolem trénovacího data (Scikit, 2010-3). Parametr  $d$  určuje stupeň polynomu a  $r$  určuje, zda nadrovina prochází počátkem souřadného systému (případ  $r = 0$ ).

Dále lze nastavit, jestli se mají vytvořit pyramidy, případně kolik jejich úrovní a práh klasifikace.

V závěru se již určí pouze složka, do které se má výsledek uložit, či zda bude pouze zobrazen a uložen v paměti.

Volba parametrů je velmi důležitá, protože zásadně ovlivňuje výsledky klasifikace a její přesnost. Na příkladu ze stanoviště Pod Liščí horou je toto názorně ukázáno v Tab. 5. Pokud jsou pásma označena jako vybraná, jedná se o výběr 164 pásem podle korelace se spektry z kontaktní sondy.

Tab. 5: Parametry metody SVM na stanovišti Pod Liščí horou

č.	pásma	kernel type	$\gamma$	PP	CPR	CP (%)	$\kappa$
1	všechna	RBF	0,003	100	0,1	86,3	0,827
2	všechna	linear		100	0,1	76,3	0,703
3	všechna	polynomial - degree 2, bias 1	0,003	100	0,1	81,9	0,770
4	všechna	sigmoid - bias 1	0,003	100	0,1	59,8	0,487
5	všechna	RBF	0,003	100	0,5	71,1	0,649
6	všechna	linear		100	0,5	71,1	0,646
7	všechna	polynomial degree - 2, bias 1	0,003	100	0,5	71,5	0,654
8	všechna	sigmoid - bias 1	0,003	100	0,5	52,6	0,424
9	všechna	RBF	0,003	50	0,1	77,5	0,712
10	všechna	linear		50	0,1	76,3	0,703
11	všechna	polynomial degree - 2, bias 1	1,000	50	0,1	76,3	0,703
12	všechna	sigmoid - bias 1	0,003	50	0,1	41,8	0,315
13	vybraná	RBF	0,006	100	0,1	85,1	0,812
14	vybraná	linear		100	0,1	85,1	0,812
15	vybraná	polynomial degree - 2, bias 1	0,006	100	0,1	85,1	0,812
16	vybraná	sigmoid - bias 1	0,006	100	0,1	72,7	0,649
17	vybraná	RBF	0,100	100	0,1	85,1	0,812
18	vybraná	polynomial degree - 2, bias 1	0,100	100	0,1	85,1	0,812
19	vybraná	sigmoid - bias 1	0,100	100	0,1	72,7	0,649
20	vybraná	polynomial - degree 4, bias 5	0,006	100	0,1	84,7	0,807
21	vybraná	sigmoid - bias 5	0,006	100	0,1	22,5	0,000

Zdroj: ENVI

Pozn.:  $\gamma$  = gamma index, PP = penalty parameter, CPR = classification probability threshold, CP = celková přesnost,  $\kappa$  = kappa index

Nejvyšší celkové přesnosti 86,3 % bylo dosaženo s kernelovou transformací RBF a při použití všech pásem. Obecně ale vyšší celkové přesnosti (okolo 85 %) vycházely při použití jenom vybraných pásem. V případě klasifikace číslo 21 algoritmus celý snímek označil jako holou půdu, ta dosáhla tedy zpracovatelské přesnosti 100 %, uživatelské 22,5 % a zbytek tříd skončil s oběma přesnostmi nulovými.

Nulové hodnoty jak pro zpracovatelskou, tak pro uživatelskou přesnost se objevily ještě v klasifikacích číslo 4, 8, 12, 16, 19 a 21 pro třídu nízké vegetace, ta očividně dělala

problémy algoritmu se sigmoidní kernelovou transformací. Vysoké hodnoty přesnosti pro smrky vykazovaly varianty metody SVM s kernelovou transformací RBF, která také byla zvolena jako nejvhodnější i pro další stanoviště.

Lépe také dopadaly klasifikace s nižším klasifikačním prahem, při další práci byla využívána hodnota 0,1.

### **3.5.4 Spectral Angle Mapping**

Metoda SAM vytváří klasifikovaný snímek na základě maximálního úhlu, který je definován při průběhu metody uživatelem. Čím menší úhel, tím více odpovídají klasifikované pixely spektrům trénovacího souboru, a tím méně je klasifikovaných pixelů. S nastavenou hodnotou nižšího spektrálního úhlu tak vznikne snímek s velkým množstvím pixelů ve třídě neklasifikováno, ale většinou s vysokou uživatelskou přesností, protože ty pixely, které vyklasifikovány byly, mají velmi vysokou shodu se spektry referenčních pixelů. Zvýšením prahu dostaneme kompaktnější snímek, ale klasifikované pixely nebudou vykazovat tak vysokou míru podobnosti s koncovými členy.

Výsledkem je klasifikovaný snímek. Dále je vygenerován i soubor snímků pro každý koncový člen, kde hodnota pixelu reprezentuje spektrální úhel od referenčního spektra pro každou třídu vyjádřený v radiánech. Nižší hodnoty vypovídají o lepší shodě s koncovým členem. Klasifikované oblasti jsou určeny na základě prahové hodnoty spektrálního úhlu. (ENVI, 2004)



## 4 Výsledky

V této kapitole budou porovnány přesnosti klasifikací na jednotlivých stanovištích pomocí tří vybraných klasifikačních metod. Ke každému stanovišti je také vytvořen kartografický výstup pro lepší vizuální porovnání a interpretaci dosažených výsledků. Mapy jsou mezi přílohami na DVD, které je součástí práce, a nahrané v SIS. V závěru kapitoly jsou porovnány metody mezi sebou.

### 4.1 Přesnosti klasifikace

Pro klasifikaci je velice důležitá její přesnost, protože na jejím základě se dá klasifikace hodnotit a porovnávat různé klasifikační metody mezi sebou. Pro určení přesnosti je nutné mít k dispozici soubor referenčních dat, tzv. Ground Truth Pixels (GTP). Jedná se o pixely, o kterých je známo, do jaké třídy v reálu patří. Soubor těchto dat byl získán na základě lesnických map Krkonošského národního parku, leteckých snímků z mapy.cz a vrstvy krajinného pokryvu CORINE Land Cover 2012 od CENIA, české informační agentury životního prostředí. Byly nalezeny reprezentativní body pro každou třídu klasifikace, které byly poté porovnány s vyklasifikovanými třídami. Počet GTP pro jednotlivé třídy se pohyboval od patnácti pro třídu holá půda na stanovišti Pod Lysou horu, kde do této třídy spadá ani ne půl procenta pixelů snímku. Nejvíce GTP pro kontrolu je u třídy smrky na stanovišti Pod Voseckou boudou, a to 282. Počty trénovacích bodů a GTP jsou uvedeny v Tab. 18 v Přílohách.

Program ENVI umožňuje vygenerování chybových matic, celkových, uživatelských i zpracovatelských přesností a kappa koeficientů.

#### ***Celková přesnost***

Udává, kolik procent pixelů bylo klasifikováno stejně za pomoci použitých klasifikačních algoritmů a vybraných GTP. Neříká nic o přesnosti jednotlivých tříd.

### ***Zpracovatelská přesnost***

Jde o pravděpodobnost, s jakou jsou pixely z dané třídy klasifikovány správně na základě GTP. Pro zpracovatele to znamená, že pokud dosáhne například 93 % přesnosti třídy louky, tak 93 % pixelů, které jsou ve skutečnosti loukami, bylo vyklasifikováno do této třídy.

### ***Uživatelská přesnost***

Udává pravděpodobnost, že pixel označený jako určitá třída do dané třídy opravdu spadá. Tedy pokud je uživatelská přesnost třídy les například 95 %, znamená to, že 95 % pixelů označených jako les v mapě, je ve skutečnosti opravdu pokryto lesem.

### ***Kappa koeficient***

Kappa koeficient porovnává klasifikaci provedenou na základě rozhodovacího pravidla s klasifikací vzniklou pomocí náhodného přiřazování pixelů do jednotlivých tříd. Vychází z předpokladu, že i při náhodném procesu klasifikace pixelů, bude určité procento zařazeno správně. Počítá se na základě vzorce:

$$\kappa = \frac{p_o - p_r}{1 - p_r}$$

Proměnná  $p_o$  značí pozorovanou přesnost,  $p_r$  přesnost dosaženou náhodným zařazením pixelů do tříd. Výsledkem je pravděpodobnost, s jakou se klasifikační metoda vyhnula chybám, které by nastaly při pouhém náhodném přiřazování tříd jednotlivým pixelům. (Doubrava a kol., 2011)

## **4.2 Stanoviště**

Ve výřezu snímku okolo každého stanoviště s kontrolními stromy byla provedena klasifikace krajinného pokryvu. Jednotlivé třídy se liší na stanovištích podle toho, co se ve výřezu nachází. Na každém stanovišti byla vyklasifikována třída smrků z trénovacího souboru, do kterého byly zařazeny čisté pixely podle konkrétních naměřených stromů. Dále se ve výřezích objevují třídy louky, kam spadá veškerý travnatý povrch, tedy i tráva prosvítající mezi jednotlivými stromy v jinak zalesněném území. Nízký porost značí hustou vegetaci, zejména kosodřevinu či nově vysázené školky. Ve třídě holá půda jsou vyklasifikovány úvozy, cesty a jinak obnažená půda. Popadané stromy značí oblasti, kde se nachází polomy a více suchých, holých, ležících stromů pohromadě tak, že zakrývají

původní pokryv. Vzhledem k podobným spektrálním charakteristikám byla tato třída v některých případech sloučena se třídou holá půda. Ve vrcholových partiích Krkonoš lze najít i obnažené skalní výchozy a suťová pole.

#### 4.2.1 Alžbětinka

Na stanovišti Alžbětinka byly zvoleny tři třídy ke klasifikaci – smrkové porosty, louky a holá půda. Výřez se nachází na okraji letové dráhy, tudíž je zde cíp bez nasnímaných dat. Metody SVM a LSU zařadily tuto část mezi holou půdu, SAM využil kategorie neklasifikováno. Přesnosti klasifikace jednotlivých metod jsou uvedeny v následující tabulce (Tab. 6):

Tab. 6: Alžbětinka - přesnosti klasifikace

<b>Linear Spectral Unmixing</b>		
celková přesnost klasifikace (%)	89,9	
kappa koeficient	0,843	
třída	zpracovatelská přesnost (%)	uživatelská přesnost (%)
smrky	96,4	100,0
louky	98,0	79,0
holá půda	66,7	95,7
<b>Support Vector Machine</b>		
celková přesnost klasifikace (%)	87,0	
kappa koeficient	0,797	
třída	zpracovatelská přesnost (%)	uživatelská přesnost (%)
smrky	100,0	88,7
louky	84,0	80,8
holá půda	69,7	95,8
<b>Spectral Angle Mapper</b>		
celková přesnost klasifikace (%)	75,4	
kappa koeficient	0,613	
třída	zpracovatelská přesnost (%)	uživatelská přesnost (%)
smrky	100,0	85,9
louky	78,0	68,4
holá půda	30,3	58,8

Zdroj: ENVI

Metody SVM a LSU dokázaly lépe vystihnout holou půdu, SAM do této třídy zahrnul i oblasti, kde se podle leteckých snímků nachází sušší vegetace. To se projevuje zejména v uživatelské přesnosti této třídy. Nejlépe se podařilo vyklasifikovat smrky pomocí LSU, má vysokou zpracovatelskou i uživatelskou přesnost. Jak SVM, tak SAM sice vykázaly stoprocentní zpracovatelskou přesnost, ale mají nižší uživatelskou přesnost, která je právě pro uživatele důležitější.

#### **4.2.2 Pod Lysou horou**

Oblast pod Lysou horou je z větší části pokrytá smrkovou monokulturou s prosvítající trávou mezi stromy a okrajem louky v severozápadní části. V pravém horním rohu prochází přes výřez zpevněná cesta, jiné oblasti s obnaženou půdou či zástavbou se v oblasti nenachází.

Přesnosti klasifikace zde vykazovaly vysoké hodnoty při použití každého z algoritmů (viz Tab. 7).

Louky i smrky se podařilo všem klasifikátorům určit s velice vysokou přesností. Hůře dopadla třída holá půda. Zde jsou horší přesnosti dány zejména malým počtem trénovacích i kontrolních bodů. Zatáčka cesty má příliš malou rozlohu na to, aby se na ni vešel potřebný počet klasifikačních pixelů, a jiné oblasti bez porostu se v území nevyskytují.

Metoda LSU má i zastoupení třídy neklasifikováno, kam případly zejména pixely, kam dopadal stín ze stromů. Takové části povrchu pak byly pro algoritmus nerozpoznatelné. Metoda SVM tyto pixely zařadila převážně ke smrkům a SAM částečně ke smrkům a částečně je vyhodnotil jako holou půdu, což snížilo přesnost této třídy.

Tab. 7: Pod Lysou horou - přesnosti klasifikace

Linear Spectral Unmixing		
celková přesnost klasifikace (%)	96,5	
kappa koeficient	0,936	
třída	zpracovatelská přesnost (%)	uživatelská přesnost (%)
smrky	100,0	100,0
louky	97,4	100,0
holá půda	46,7	98,9
Support Vector Machine		
celková přesnost klasifikace (%)	97,9	
kappa koeficient	0,961	
třída	zpracovatelská přesnost (%)	uživatelská přesnost (%)
smrky	100,0	100,0
louky	96,3	99,5
holá půda	93,3	66,7
Spectral Angle Mapping		
celková přesnost klasifikace (%)	94,4	
kappa koeficient	0,898	
třída	zpracovatelská přesnost (%)	uživatelská přesnost (%)
smrky	100,0	96,1
louky	92,1	100,0
holá půda	60,0	39,1

Zdroj: ENVI

#### 4.2.3 Pod Liščí horou

Na stanovišti Pod Liščí horou byl více rozmanitý krajinný pokryv, proto zde bylo vyklasifikováno celkem pět tříd (smrky, louky, nízká vegetace, popadané stromy a holá půda). Opět se zde ve výřezu objevuje kus bez nasnímaných dat. Každý algoritmus tentokrát tuto situaci vyřešil jinak. SAM zařadil tuto část do třídy neklasifikováno, LSU pod holou půdu a SVM k popadaným holým stromům.

Přesnosti jednotlivých klasifikačních metod jsou uvedeny v Tab. 8:

Tab. 8: Pod Liščí horou - přesnosti klasifikace

<b>Linear Spectral Unmixing</b>		
celková přesnost klasifikace (%)	74,7	
kappa koeficient	0,680	
třída	zpracovatelská přesnost (%)	uživatelská přesnost (%)
smrky	96,7	74,4
louky	60,7	86,1
nízká vegetace	51,2	53,9
popadané stromy	90,3	75,7
holá půda	75,0	80,8
<b>Support Vector Machine</b>		
celková přesnost klasifikace (%)	86,3	
kappa koeficient	0,827	
třída	zpracovatelská přesnost (%)	uživatelská přesnost (%)
smrky	98,3	84,3
louky	91,8	93,3
nízká vegetace	73,2	90,9
popadané stromy	90,3	75,7
holá půda	75,0	85,7
<b>Spectral Angle Mapping</b>		
celková přesnost klasifikace (%)	88,8	
kappa koeficient	0,858	
třída	zpracovatelská přesnost (%)	uživatelská přesnost (%)
smrky	96,7	93,6
louky	95,1	92,1
nízká vegetace	90,2	86,1
popadané stromy	90,3	75,7
holá půda	71,4	90,9

Zdroj: ENVI

Nejvyšší celkové přesnosti dosáhla metoda SAM, nejhůře z tohoto pohledu naopak dopadla metoda LSU. Obecně nižší přesnost klasifikace může být dána rozdrobeností krajinného pokryvu, kdy je pak obtížné najít jak čisté pixely pro samotnou učící fázi klasifikace, tak pak reprezentativní vzorky pro ověření přesnosti klasifikace. Samotný snímek nemá dostatečné prostorové rozlišení, aby postihl všechny soliterní stromy, a lesnické mapy také nejsou dostatečně podrobné.

Algoritmus metody SVM měl problém s rozpoznáním suché trávy na loukách severozápadně od cesty protínající území. Velkou část této oblasti zařadil mezi holou půdu, která tam ale podle leteckých snímků není.

#### 4.2.4 Modrý důl

V oblasti Modrého dolu se v centrální části výřezu nachází výrazný lesní porost. V severní části jsou suťová pole, na západě louky a na východě vysázené malé stromky.

Tab. 9: Modrý důl - přesnosti klasifikace

<b>Linear Spectral Unmixing</b>		
celková přesnost klasifikace (%)	80,8	
kappa koeficient	0,747	
třída	zpracovatelská přesnost (%)	uživatelská přesnost (%)
smrky	60,0	98,4
louky	89,7	81,4
nízká vegetace	84,1	54,6
suťová pole	95,1	100,0
<b>Support Vector Machine</b>		
celková přesnost klasifikace (%)	93,8	
kappa koeficient	0,917	
třída	zpracovatelská přesnost (%)	uživatelská přesnost (%)
smrky	91,0	94,8
louky	96,2	96,2
nízká vegetace	90,5	82,6
suťová pole	97,6	100,0
<b>Spectral Angle Mapping</b>		
celková přesnost klasifikace (%)	89,5	
kappa koeficient	0,860	
třída	zpracovatelská přesnost (%)	uživatelská přesnost (%)
smrky	75,0	96,2
louky	96,2	96,2
nízká vegetace	92,1	68,2
suťová pole	98,8	98,8

Zdroj: ENVI

Právě ve východní části jsou nejzřetelnější rozdíly mezi jednotlivými klasifikačními metodami. SVM a SAM tuto oblast převážně označily jako nízkou vegetaci, tedy stejně

jako porosty kosodřeviny v severní části výřezu, s travnatými částmi. LSU zde také vyklasifikovala nízké porosty, ale daleko více pixelů přiřadila do třídy smrků. Ač je celková přesnost klasifikace LSU nejnižší (viz Tab. 9), klonila bych se k tomuto pojetí, protože některé ze stromků určitě již vykazují znaky vzrostlých smrků spíše než mladé nízké vegetace. Algoritmus LSU dokáže rozlišit i rozdíly odrazivosti v rámci jednoho pixelu, takže by tato metoda měla být vhodná právě na rozlišení jemných nuancí. Naopak lesnické mapy nedokážou rozlišit jednotlivé stromy. Na leteckých snímcích jsou rozpoznatelné větší details, je však obtížnější informaci o polohách jednotlivých stromů přenést do výřezu snímku pro potřeby verifikace klasifikace. Díky tomu vycházejí přesnosti u metody LSU nižší než u dalších dvou algoritmů.

Ve všech metodách dopadla nejlépe klasifikace suťových polí. Ta mají výrazně odlišné spektrální vlastnosti od ostatních klasifikovaných tříd, které jsou všechny vegetační.

#### **4.2.5 Pudlava**

Oblast okolo rozcestí Pudlava je velmi členitá, co se týče jak terénu, tak krajinného pokryvu. Ke klasifikaci bylo zvoleno pět tříd (smrky, louky, popadané stromy, holá půda a skály). Přesnosti všech metod jsou vysoké, zejména smrkové porosty dosáhly velmi vysokých hodnot (viz Tab. 10).

Jako nejproblematictější se ukázala klasifikace holé půdy, v tomto případě zastoupená zejména cestami protínajícími řešené území. Nejlépe rozlišitelné jsou cesty na snímku klasifikovaném pomocí metody SVM. Algoritmus LSU vyhodnotil některé pixely, které by měly spadat právě do třídy holé půdy, jako neklasifikované, čímž se snížila zejména zpracovatelská přesnost této třídy v dané metodě. SAM zase hůře rozlišoval popadané stromy (polomy) od holé půdy.

LSU dokázal odlišit jednotlivé stromy, takže třídy ve výsledném klasifikovaném snímku vypadají více rozdrobeně. Jak SVM, tak SAM mají plochy jednotlivých tříd kompaktnější.



Tab. 10: Pudlava - přesnosti klasifikace

<b>Linear Spectral Unmixing</b>		
celková přesnost klasifikace (%)	93,0	
kappa koeficient	0,905	
třída	zpracovatelská přesnost (%)	uživatelská přesnost (%)
smrky	100,0	100,0
louky	95,6	78,3
popadané stromy	86,8	93,9
holá půda	60,6	95,2
skály	95,5	100,0
<b>Support Vector Machine</b>		
celková přesnost klasifikace (%)	94,1	
kappa koeficient	0,920	
třída	zpracovatelská přesnost (%)	uživatelská přesnost (%)
smrky	100,0	100,0
louky	95,6	86,7
popadané stromy	81,1	95,6
holá půda	78,8	81,3
skály	97,0	94,1
<b>Spectral Angle Mapping</b>		
celková přesnost klasifikace (%)	91,4	
kappa koeficient	0,883	
třída	zpracovatelská přesnost (%)	uživatelská přesnost (%)
smrky	100,0	99,3
louky	95,6	90,3
popadané stromy	75,5	80,0
holá půda	57,6	70,4
skály	97,0	91,4

Zdroj: ENVI

## 4.2.6 Pašerácký chodníček

Největším problémem při klasifikaci členité oblasti Pašerácký chodníček bylo zařízlé údolí potoka, kde východní strana byla výrazně zastíněna oproti zbytku území.

Tab. 11: Pašerácký chodníček - přesnosti klasifikace

Linear Spectral Unmixing		
celková přesnost klasifikace (%)	66,9	
kappa koeficient	0,585	
třída	zpracovatelská přesnost (%)	uživatelská přesnost (%)
smrky	62,5	52,6
louky	93,3	71,4
nízká vegetace	79,7	59,3
popadané stromy, holá půda	38,1	91,8
stín	92,5	80,4
Support Vector Machine		
celková přesnost klasifikace (%)	88,0	
kappa koeficient	0,848	
třída	zpracovatelská přesnost (%)	uživatelská přesnost (%)
smrky	85,4	90,1
louky	98,7	76,3
nízká vegetace	85,9	90,2
popadané stromy, holá půda	80,5	99,0
stín	100,0	83,3
Spectral Angle Mapping		
celková přesnost klasifikace (%)	84,9	
kappa koeficient	0,809	
třída	zpracovatelská přesnost (%)	uživatelská přesnost (%)
smrky	77,9	78,7
louky	98,7	85,1
nízká vegetace	81,3	88,1
popadané stromy, holá půda	83,1	99,0
stín	100,0	67,2

Zdroj: ENVI

Pokud se klasifikovalo bez třídy stín, tato část území se zařadila buď mezi neklasifikované pixely, nebo do různých jiných tříd. Přesnosti klasifikací pak klesaly.

K ostatním klasifikovaným třídám (smrky, louky, nízká vegetace, holá půda a popadané stromy) proto byla přidána ještě třída stín.

SVM a SAM při takovýchto podmínkách dosáhly přesností přes 80 % (viz Tab. 11), LSU stále vykazoval nízké přesnosti okolo 65 %. Metoda klasifikovala jednotlivé stromy, ať už smrky, tak kosodřevinu, a tím pádem rozdrobila území na jednotlivé pixely.

Nejvyšší celkovou přesnost vykazala metoda SVM, nejlépe u této metody vychází i přesnosti klasifikace smrků.

#### **4.2.7 Václavák**

Stanoviště Václavák se nachází blízko vrcholu Černé hory, výřezem prochází několik zpevněných cest, je zde také Černohorské rašeliniště. Oblast byla klasifikována do pěti tříd – smrky, louky, nízká vegetace (zarostlé okraje rašeliniště, kosodřevina), popadané stromy (holá torza stromů) a holá půda (cesty a silnice). Rozdíly v jednotlivých klasifikacích jsou znatelné, a to i co se týče jejich přesností (viz Tab. 12).

Metoda LSU nebyla schopná vyčlenit nízkou vegetaci, zpracovatelská i uživatelská přesnost okolo 10 % je alarmující výsledek. Oba ostatní algoritmy se s touto třídou dokázaly vyrovnat, ale LSU, ač prováděna se stejným trénovacím souborem dat, nezařadila vůbec oblast okolo rašeliniště tam, kam by patřit měla.

Tab. 12: Václavák - přesnosti klasifikace

<b>Linear Spectral Unmixing</b>		
celková přesnost klasifikace (%)	67,2	
kappa koeficient	0,553	
třída	zpracovatelská přesnost (%)	uživatelská přesnost (%)
smrky	70,9	88,8
louky	88,8	40,1
nízká vegetace	2,2	11,1
popadané stromy	89,2	92,1
holá půda	48,2	100,0
<b>Support Vector Machine</b>		
celková přesnost klasifikace (%)	88,3	
kappa koeficient	0,838	
třída	zpracovatelská přesnost (%)	uživatelská přesnost (%)
smrky	97,9	97,9
louky	87,9	76,4
nízká vegetace	89,1	82,0
popadané stromy	53,9	67,3
holá půda	88,2	96,2
<b>Spectral Angle Mapping</b>		
celková přesnost klasifikace (%)	79,0	
kappa koeficient	0,708	
třída	zpracovatelská přesnost (%)	uživatelská přesnost (%)
smrky	97,4	95,4
louky	82,2	80,0
nízká vegetace	87,0	75,5
popadané stromy	26,2	36,2
holá půda	60,0	58,0

Zdroj: ENVI

#### 4.2.8 Pod Voseckou boudou

Okolí stanoviště Pod Voseckou boudou je pokryto smrkovými porosty, nebo trávou, loukami. Výřez protíná několik cest a koryto potoka, tyto byly zařazeny do třídy holé půdy. Přesnosti klasifikace jsou vysoké u SVM a LSU, rozlišit tyto tři druhy krajinného pokryvu jim nedělá problém (viz Tab. 13). Algoritmus metody SAM hůře odlišil holou

půdu, ani cesty, ani koryto nejsou zřetelné, což se projevilo i v přesnosti klasifikace, která u této třídy klesla ve zpracovatelské přesnosti pod 50 %.

Tab. 13: Pod Voseckou boudou - přesnosti klasifikace

Linear Spectral Unmixing		
celková přesnost klasifikace (%)	95,9	
kappa koeficient	0,927	
třída	zpracovatelská přesnost (%)	uživatelská přesnost (%)
smrky	100,0	98,3
louky	98,4	93,1
holá půda	67,8	93,0
Support Vector Machine		
celková přesnost klasifikace (%)	96,6	
kappa koeficient	0,941	
třída	zpracovatelská přesnost (%)	uživatelská přesnost (%)
smrky	99,7	97,9
louky	94,8	96,3
holá půda	88,1	91,2
Spectral Angle Mapping		
celková přesnost klasifikace (%)	90,0	
kappa koeficient	0,820	
třída	zpracovatelská přesnost (%)	uživatelská přesnost (%)
smrky	100,0	87,6
louky	89,0	96,1
holá půda	45,8	81,8

Zdroj: ENVI

## 4.3 Porovnání výsledků

V předchozích podkapitolách byly uvedeny klasifikace pomocí metod Linear Spectral Unmixing (LSU), Support Vector Machine (SVM) a Spectral Angle Mapper (SAM) pro jednotlivá stanoviště s příslušnými přesnostmi těchto klasifikací. V následujících tabulkách jsou uvedeny celkové přesnosti pro jednotlivá stanoviště a poté i přesnosti pro třídu smrků, jejíž klasifikace byla primárním cílem v této práci. Tučně jsou v obou tabulkách zvýrazněny přesnosti přesahující 90 %.

V Tab. 14 je uveden souhrn celkových přesností a kappa indexů pro všechna stanoviště. Z výsledků zde uvedených vyplývá, že nejvyšších přesností klasifikací dosahovala metoda SVM, která na polovině stanovišť vyklasifikovala krajinný pokryv s celkovou přesností přesahující 90 % a na všech stanovištích přesáhla celková přesnost 85 %.

Průměrná celková přesnost je nejnižší u metody LSU. Zde je však vysoký rozptyl hodnot, kdy na jedné straně na třech stanovištích vykazuje velmi vysoké hodnoty přesnosti, ale na stanovištích Pašerácký chodníček a Václavák jsou celkové přesnosti nízké. Metoda SAM má vyšší průměr celkových přesností než LSU, protože nedosahuje takových extrémů.

Tab. 14: Porovnání celkových přesností na jednotlivých stanovištích

	LSU		SVM		SAM		průměr	
	CP (%)	$\kappa$	CP (%)	$\kappa$	CP (%)	$\kappa$	CP (%)	$\kappa$
A	89,9	0,843	87,0	0,797	75,4	0,613	84,1	0,751
LI	74,7	0,680	86,3	0,827	88,8	0,858	83,3	0,788
LH	<b>96,5</b>	0,936	<b>97,9</b>	0,961	<b>94,4</b>	0,898	<b>96,3</b>	0,932
MD	80,8	0,747	<b>93,8</b>	0,917	89,5	0,860	88,0	0,841
P	<b>93,0</b>	0,905	<b>94,1</b>	0,920	<b>91,4</b>	0,883	<b>92,8</b>	0,903
PA	66,9	0,585	88,0	0,848	84,9	0,809	80,0	0,747
V	67,2	0,553	88,3	0,838	79,0	0,708	78,1	0,699
VB	<b>95,9</b>	0,927	<b>96,6</b>	0,941	<b>90,0</b>	0,820	<b>94,2</b>	0,896
průměr	83,1	0,772	<b>91,5</b>	0,881	86,7	0,806		
$\delta$	11,6		4,3		6,1			

Zdroj: ENVI, autorka

Pozn.: CP = celková přesnost,  $\kappa$  = kappa index,  $\delta$  = směrodatná odchylka

Jako nejlépe klasifikovatelná se ukázala stanoviště Pod Lysou horou, Pod Voseckou boudou a Pudlava. Ani na jednom z těchto stanovišť se nenachází třída nízká vegetace. Metody zde tak neodlišují smrkové porosty od jiných stromových porostů. Luční a lesní společenstva vykazují větší rozdíly ve spektrálních charakteristikách, takže je jednodušší od sebe tyto dva druhy pokryvu oddělit.

V Tab. 15 jsou uvedeny zpracovatelské a uživatelské přesnosti pro třídu smrků na jednotlivých stanovištích. Nejlépe se při separaci smrkových porostů jeví opět metoda SVM. U ní, stejně jako v případě metody SAM, je vyšší přesnost zpracovatelská než uživatelská. Jako v předchozím případě, i zde má metoda LSU průměrné přesnosti nejnižší a vykazuje největší rozptyl hodnot mezi jednotlivými stanovišti. Na rozdíl od ostatních

dvou metod ale dosáhla vyšších uživatelských přesností než zpracovatelských. To je pro cílového uživatele klasifikovaných snímků lepší, protože se můžou na klasifikaci spolehnout. Na třech stanovištích (Alžbětinka, Pod Lysou horou a Pudlava) vykázala metoda LSU stoprocentní uživatelskou přesnost. Samozřejmě je i toto číslo nutno brát s rezervou, protože přesnost klasifikace je měřena na určitém počtu vybraných kontrolních bodů, nekontroluje se každý pixel.

Tab. 15: Porovnání přesností u třídy smrky na jednotlivých stanovištích

	LSU		SVM		SAM		průměr	
	ZP (%)	UP (%)	ZP (%)	UP (%)	ZP (%)	UP (%)	ZP (%)	UP (%)
A	<b>96,4</b>	<b>100,0</b>	<b>100,0</b>	88,7	<b>100,0</b>	85,9	<b>98,8</b>	<b>91,6</b>
LI	<b>96,7</b>	74,4	<b>98,3</b>	84,3	<b>96,7</b>	<b>93,6</b>	<b>97,2</b>	84,1
LH	<b>100,0</b>	<b>100,0</b>	<b>100,0</b>	<b>100,0</b>	<b>100,0</b>	<b>96,1</b>	<b>100,0</b>	<b>98,7</b>
MD	60,0	<b>98,4</b>	<b>91,0</b>	<b>94,8</b>	75,0	<b>96,2</b>	75,3	<b>96,4</b>
P	<b>100,0</b>	<b>100,0</b>	<b>100,0</b>	<b>100,0</b>	<b>100,0</b>	<b>99,3</b>	<b>100,0</b>	<b>99,8</b>
PA	62,5	52,6	85,4	<b>90,1</b>	77,9	78,7	75,3	73,8
V	70,9	88,8	<b>97,9</b>	<b>97,9</b>	<b>97,4</b>	<b>95,4</b>	88,7	<b>94,0</b>
VB	<b>100,0</b>	<b>98,3</b>	<b>99,7</b>	<b>97,9</b>	<b>100,0</b>	87,6	<b>99,9</b>	<b>94,6</b>
průměr	85,8	89,0	<b>96,5</b>	<b>94,2</b>	<b>93,4</b>	<b>91,6</b>		
δ	16,8	16,1	5,1	5,5	9,8	6,5		

Zdroj: ENVI, autorka

Pozn.: ZP = zpracovatelská přesnost, UP = uživatelská přesnost, δ = směrodatná odchylka

S nejnižšími přesnostmi skončilo stanoviště Pašerácký chodníček, kde se na výřezu snímku nachází oblast s hluboce zahloubeným údolím potoka, kde jedna ze strání byla při pořizování snímků výrazně zastíněná oproti okolí. V případě tohoto stanoviště tak bylo potřeba vytvořit třídu stín, a přesto měly metody s klasifikací problémy. Většina zastíněné oblasti je pokryta smrkovými porosty, tudíž zde byl problém při separaci smrků. Nejhůře se se situací vyrovnala metoda LSU, kde přesnosti třídy smrků klesly až k 60 %. To se samozřejmě promítá i do zprůměrovaných přesností.

## 5 Diskuze

Koncové členy získané na základě spekter naměřených v laboratoři byly shledány jako vhodné pro klasifikaci vegetačního pokryvu. Pro přesnější výsledky je žádoucí vybrat ze snímků vhodná pásma pro klasifikaci podle korelace s daty z terénu. K této práci byla k dispozici data naměřená v terénu na konkrétních smrcích, bylo tedy možné použít terénní data jako koncové členy pouze pro smrkové porosty. Ostatní třídy byly klasifikovány na základě koncových členů vybraných čistě ze snímků bez laboratorních měření. Jako dalším rozšířením této práce do budoucna se tak nabízí další terénní výzkum a naměření spekter ostatních typů povrchu. Případně by bylo možné využít i již existující spektrální knihovny například pro klasifikaci skalních výchozů na základě jejich geologického složení. Tuto možnost jsem v této práci zavrhl, neboť přesnosti klasifikace pro třídu skal vycházely velice vysoké, problém s identifikací skalních výchozů neměla žádná metoda, a geologické charakteristiky území nebyly předmětem či cílem práce.

Metoda Linear Spectral Unmixing se neprojevila jako výrazně nejlepší na daných datech. To, že tato metoda nedostála očekávání, uvedla ve svém článku například i C. Zayas-Santiago (2009), která pracovala s daty z družice IKONOS a snažila se o klasifikaci portorických korálových útesů. Nejlépe bylo území útesů vyklasifikováno za pomoci metody nejmenších vzdáleností, LSU nedopadla dobře kvůli nízkému prostorovému rozlišení snímků. Díky tomu, že metoda pracuje na subpixelové úrovni, je schopná území rozdělit opravdu podrobně, a tedy výsledný klasifikovaný snímek se jeví velmi rozdrobeně. Zde také nastávaly problémy při tvorbě kontrolního souboru dat pro počítání přesností. Operátor není schopen rozlišit na snímcích jednotlivé stromy i s využitím několika zdrojů dat o území a jeho pokryvu. Vhodnější by bylo mít pro kontrolu přesností snímek s vyšším prostorovým rozlišením, který by se dal využít jako referenční automaticky. Lidský faktor zanáší vždy chyby.

Metoda LSU by mohla být využita například při zkoumání hustoty zalesnění. Dalo by se třeba porovnávat pokrytí stromy před a po různých přírodních katastrofách, silných větrech či sesuvech půdy, které způsobují polomy v lesních společenstvech. Podle hustoty zalesnění by se také dalo plánovat budoucí zalesňování. Na základě vývoje zalesnění by pak bylo možné zkoumat například vlivy znečištěného ovzduší či jiné lidské činnosti na



lesní porosty, a to nejen v chráněných oblastech. Zajímavé by bylo třeba sledovat zalesnění Krušných hor od doby, kdy svahy byly pokryté jen odumřelými stromy, až do současnosti, či hustotu zalesnění v Tatranském národním parku před a po orkánu v roce 2004.

Vizuálně působí lépe výsledky po použití metody Support Vector Machine, a to díky tomu, že na snímku jsou kompaktnější plochy a uživatel tak získá lepší představu o zkoumaném území. Tato metoda také vykazovala nejvyšší hodnoty celkové přesnosti a zpracovatelské i uživatelské přesnosti pro třídu smrkových porostů. Pro použití například při tvorbě map krajinného pokryvu, kdy není potřeba mít odlišené jednotlivé stromy a je spíše žádoucí získat zóny pro jednotlivé třídy, bude tato metoda vhodnější, uživatel získá ucelenější přehled o území.

Metoda Spectral Angle Mapper se ukázala jako vhodnou, pokud chceme získat vysokou uživatelskou přesnost. Pokud se metodě zadá malý úhel, vyklasifikuje jen ty pixely, které vykazují nejvyšší shodu s trénovacím souborem dat. Je pak tedy možné se spolehnout na to, že když byl pixel zařazen do nějaké třídy, s největší pravděpodobností se v terénu tento druh povrchu opravdu nachází. Na druhou stranu s takto nastavenými parametry metoda dokáže vyklasifikovat většinou přibližně padesát procent pixelů a zbytek zařadí mezi neklasifikované. Tím se ve výsledném snímku objevují velké oblasti bez přiřazených tříd, kde uživatel neví, co se na nich nachází. Zpracovatelská i celková přesnost díky tomu rapidně klesají, proto v této práci byl využit jako prahový úhel 0,5 rad. Území je pak klasifikováno celé, ale s nižší uživatelskou přesností. Tato metoda by se dala použít, když bude potřeba si vytipovat oblasti s určitým typem povrchu, například před terénním průzkumem, kdy si vědci mohou najít konkrétní místo, na které pak půjdou pracovat.

## 6 Závěr

Cílem této diplomové práce byla klasifikace smrkových porostů pomocí metod obrazové a laboratorní spektroskopie. V úvodní rešeršní části jsou popsány obecné principy dálkového průzkumu Země a klasifikace vegetace. Podrobněji jsou v kapitole rozebrány metody subpixelové klasifikace a možnosti využití hyperspektrálních dat.

Využita byla hyperspektrální data ze senzoru APEX nasnímaná během leteckého snímkování v roce 2012 v rámci projektu EUFAR. Ve stejném roce proběhla i terénní kampaň, během které byly nasbírány vzorky jehlic smrku ztepilého, u kterých byla následně pomocí kontaktní sondy naměřena spektrální odrazivost. Vybráno bylo osm stanovišť, čtyři ve východní a čtyři v západní části Krkonošského národního parku, na každém se sbíraly větve z pěti stromů. Tato data byla v následných klasifikacích použita pro tvorbu trénovacích souborů pro třídu smrků.

Klasifikace krajinného pokryvu byla provedena na osmi výřezech snímků, které pokrývají oblast okolo vybraných stanovišť. Vždy byla zahrnuta třída smrků, která byla stěžejní pro tuto práci, ostatní třídy byly voleny podle potřeby na daném výřezu. Použity byly tři metody řízené klasifikace, konkrétně Linear Spectral Unmixing, Support Vector Machine a Spectral Angle Mapper. Pro každé stanoviště byly spočítány přesnosti klasifikace při použití každé ze tří popsaných metod, které byly následně popsány.

Ve výsledcích práce jsou zhodnoceny přesnosti jednotlivých metod, jejich výhody a nevýhody. V diskuzi jsou pak ještě rozebrány podrobněji možnosti použití a dalšího využití metod. Z hlediska přesností klasifikace byla zhodnocena i jednotlivá stanoviště.

Jedním z úkolů práce bylo i zhodnocení využití spekter naměřených kontaktní sondou pro extrakci koncových členů pro subpixelovou metodu Linear Spectral Unmixing. Tato metoda se ukázala jako vhodná, pokud se vybrala správná pásma pro klasifikaci. Avšak ani s takto vybranými pásmy a koncovými členy nebyly výsledky subpixelové klasifikace pomocí metody Linear Spectral Unmixing výrazně lepší než u ostatních dvou klasifikačních metod. Možné příčiny této skutečnosti jsou rozebrány v kapitole Diskuze.

Pro všechna stanoviště byly také zpracovány mapy krajinného pokryvu vytvořené pomocí zkoumaných klasifikačních metod. S pomocí kartografických výstupů je možné

vizuálně porovnat výstupy jednotlivých klasifikací se snímkem daného stanoviště v nepravých barvách.

Na přiloženém CD jsou uloženy výřezy hyperspektrálních snímků pořízených pomocí sondy APEX i jejich klasifikace. Také jsou zde uloženy hodnoty spektrální odrazivosti jednotlivých vzorků stromů naměřené pomocí kontaktní sondy.

## Zdroje

ASNER, G. P., HEIDEBRECHT, K. B. (2002): Spectral unmixing of vegetation, soil and dry carbon cover in arid regions: comparing multispectral and hyperspectral observations. *International Journal of Remote Sensing*. 2002. roč. 23, č. 19, str. 3939 – 3956.

ARCHIBALD, R., FANN, G. (2007): Feature Selection and Classification of Hyperspectral Images With Support Vector Machines. *IEEE Geoscience and Remote Sensing Letters*. 2007. roč. 4, č. 4, str. 674 – 677.

AVERBUCH, A., ZHELUDEV, M. (2012): Two Linear Unmixing Algorithms to Recognize Targets Using Supervised Classification and Orthogonal Rotation in Airborne Hyperspectral Images. *Remote Sensing*. 2012. č. 4, str. 532 – 560.

BANNARI, A. a kol. (2006): Estimating and mapping crop residues cover on agricultural lands using hyperspectral and IKONOS data. *Remote Sensing of Environment*. 2006. č. 104, str. 447 – 459.

BEAN, D. (2000): *Classifying Vegetation Using Remote Sensing*. [online]. [cit. 15. 9. 2013]. Dostupné z URL: <[http://www.geog.ubc.ca/courses/geog570/talks\\_2000/classifyingvegetation.htm](http://www.geog.ubc.ca/courses/geog570/talks_2000/classifyingvegetation.htm)>.

BOVOLO, F., BRUZZONE, L., CARLIN, L. (2010): A Novel Technique for Subpixel Image Classification Based on Support Vector Machine. *Image Processing, IEEE Transactions on*. 2010. roč. 19, č. 11, str. 2983 – 2999.

CSR (1998): *Analysis of Hyperspectral Imagery*. [online]. University of Texas. Center for Space Research. [cit. 12. 11. 2013]. Dostupné z URL: <<http://www.csr.utexas.edu/projects/rs/hrs/analysis.html>>.

ČAPEK, R. (1988): *Dálkový průzkum Země: dočasná vysokoškolská učebnice*. 1. vyd. Praha: Ministerstvo školství ČSR. 1988. 244 str.

DALPONTE, M., ORKA, H. O., GOBAKKEN, T., GIANELLE, D., NAESSET, E. (2013): Tree Species Classification in Boreal Forests With Hyperspectral Data. *Geoscience and Remote Sensing, IEEE Transactions on*. 2013. roč. 51, č. 5, str. 2632 – 2645.

DORIČ, R. (2013): *Možnosti objektovo orientovanej klasifikácie pri monitoringu lúčnej vegetácie a manažmentových zásahov v Krkonošskom národnom parku*. Diplomová práce. Univerzita Karlova v Praze, Přírodovědecká fakulta, Katedra aplikované geoinformatiky a kartografie. 2013. 78 s.

DOUBRAVA, P., JIRÁSKOVÁ, L., PETRUCHOVÁ, J., ROUŠAROVÁ, Š., ŘEŘIČKA, J., SUCHÁNEK, Z. (2011): *Metody dálkového průzkumu v projektu Národní inventarizace kontaminovaných míst*. 1. Vydání. Praha: CENIA. 2011. ISBN 978-80-85087-91-8.

ENVI (2004): ENVI User's Guide. [online]. [cit.14.6.2014.]. Dostupné z URL: <[http://aviris.gl.fcen.uba.ar/Curso\\_SR/biblio\\_sr/ENVI\\_userguid.pdf](http://aviris.gl.fcen.uba.ar/Curso_SR/biblio_sr/ENVI_userguid.pdf)>.

GRUNINGER, J., RATKOWSKI, A. J., HOKE, M. L. (2004): The sequential maximum angle convex cone (SMACC) endmember model. *SPIE Proceeding, Algorithms for Multispectral, Hyperspectral and Ultraspectral Imagery*. 2004. č. 5425 – 1.

HOFFER, R. M. (1978): Biological and physical considerations in applying computer-aided analysis techniques to remote sensor data. In Swain, P.H., Davis, S. M. (1978): *Remote Sensing: The Quantitative Approach*. McGraw-Hill Book Company. 396 str. [online]. [cit. 25.5.2014]. Dostupné z: <<http://www.scotland.gov.uk/Publications/2009/11/06110108/6>>.

KOLÁŘ, J., HALOUNOVÁ, L., PAVELKA, K. (1997): *Dálkový průzkum Země 10*. 1. vydání. Praha: Vydavatelství ČVUT. 1997. 164 str. ISBN 80-01-01567-X.

KOMEŠTÍKOVÁ, P. (2006): *Vegetační indexy*. Seminární práce. Univerzita Jana Evangelisty Purkyně v Ústí nad Labem, Fakulta životního prostředí, Katedra informatiky a geoinformatiky. 2006. 14 str.

MÁLKOVÁ, H. (2010): *Klasifikace land cover z hyperspektrálních dat v rekultivovaných oblastech sokolovské hnědouhelné pánve*. Diplomová práce. Univerzita Karlova v Praze, Přírodovědecká fakulta, Katedra aplikované geoinformatiky a kartografie. 2010, 55 s.

MARTIN, M. E., NEWMAN S.D., ABER J. D., CONGALTON R. G. (1998): Determining Forest Species Composition Using High Spectral Resolution Remote Sensing Data. *Remote Sensing of Environment*. 1998. č. 65, str. 249 – 254.

MELGANI, F., BRUZZONE, L. (2004): Classification of Hyperspectral Remote Sensing Images With Support Vector Machines. *IEEE Transactions on Geoscience and Remote Sensing*. 2004. roč. 42., č. 8, str. 1778 – 1790.

MIDDLETON, A. a kol. (2003): *Analysis of hyperspectral airborne HyMap data for vegetation mapping around Lahnaslampi talc mine, Finland*. Presented at the 3rd EARSeL Workshop on Imaging Spectroscopy, Herrsching, 13-16 May 2003.

NEVILLE, R. A. a kol. (1999): *Automatic Endmember extraction from hyperspectral data for mineral exploration*. Presented at the Fourth International Airborne Remote Sensing Conference and Exhibition. 21st Canadian Symposium on Remote Sensing, Ottawa, Ontario, Canada, 21-24 June 1999.

REES, W. G. (2001): *Physical principles of remote sensing*. 2nd edition. Cambridge: Cambridge University Press. 2001. 343 str. ISBN 0-521-66948-0.

RICHTER, N., STAENZ, K., KAUFMANN, H. (2008): Spectral unmixing of airborne hyperspectral data for baseline mapping of mine tailings areas. *International Journal of Remote Sensing*. 2008. roč. 29, č. 13, str. 3937 – 3956.

SANDMEIER, S., DEERING, D. W. (1999): Structure Analysis and Classification of Boreal Forests Using Airborne Hyperspectral BRDF Data from ASAS. *Remote Sensing of Environment*. 1999. č. 69, str. 281 – 295.

SCHOWENGERDT, R. A. (2007): *Remote Sensing. Models and Methods for Image Processing*. 3rd edition. Elsevier Inc.. 2007. 560str. ISBN 0-12-369407-8.

SCIKIT (2010-2013): RBF SVM parameters. [online]. [cit. 22.6.2014]. Dostupné z: <[http://scikit-learn.org/stable/auto\\_examples/svm/plot\\_rbf\\_parameters.html](http://scikit-learn.org/stable/auto_examples/svm/plot_rbf_parameters.html)>.

STANGROOM, J (2014): Social Science Statistics. [online]. [cit. 14.6.2014]. Dostupné z: <<http://www.socscistatistics.com/tests/pearson/>>.

SUCHÁ, R. (2013): *Stanovení obsahu ligninu v jehlicích smrku ztepilého (Picea abies l. karst.) pomocí laboratorní a obrazové spektroskopie*. Diplomová práce. Univerzita Karlova v Praze, Přírodovědecká fakulta, Katedra aplikované geoinformatiky a kartografie. 2013, 129 s.

ZACHOVÁ, K. (2011): *Určení množství chlorofylu v porostech břízy bradavičnaté a borovice lesní s využitím hyperspektrálních dat*. Diplomová práce. Univerzita Karlova v Praze, Přírodovědecká fakulta, Katedra aplikované geoinformatiky a kartografie. 2011, 58 s.

ZAYAS-SANTIAGO, C. C. (20??): *Application of Linear Spectral unmixing to Enrique reef for classification*. University of Puerto Rico Mayaguez. Marine Sciences Department. [online]. [cit. 17. 8. 2014]. Dostupné z URL: <[http://www.gers.uprm.edu/geol6225/pdfs/c\\_zayas.pdf](http://www.gers.uprm.edu/geol6225/pdfs/c_zayas.pdf)>.

## Přílohy

Mezi přílohami jsou i kartografické výstupy jednotlivých stanovišť. V tištěné podobě je zde prezentováno stanoviště Pudlava, zbytek map je nahrán na přiloženém DVD a ve Studentském informačním systému.

Tab. 16: Stanoviště východ - souřadnice stromů

	zeměpisná délka (°v.d.)	zeměpisná šířka (°s.š.)	nadmořská výška (m n.m.)
<b>Modrý důl</b>			1237
MD-A	15,70706	50,71955	
MD-B	15,70711	50,71955	
MD-F	15,70745	50,71963	
MD-H	15,70770	50,71953	
MD-K	15,70791	50,71940	
<b>Pašerácký chodníček</b>			1317
PA-C1	15,76558	50,73974	
PA-E1	15,76592	50,73983	
PA-E8	15,76539	50,73960	
PA-E10	15,76566	50,73980	
PA-e2c7	15,76612	50,73965	
PA-c7b	15,76616	50,73964	
<b>Václavák</b>			1190
V-44	15,74323	50,65905	
V-48	15,74335	50,65902	
V-91	15,74346	50,65910	
V-93	15,74346	50,65912	
V-146	15,74368	50,65913	
<b>Pod Liščí boudou</b>			1260
LI-52	15,68993	50,68666	
LI-56	15,69002	50,68660	
LI-81	51,68968	50,68663	
LI-91	15,68981	50,68679	
LI-102	15,68960	50,68650	
LI-102b	15,68953	50,68653	



Tab. 17: Stanoviště západ - souřadnice stromů

	zeměpisná délka (°v.d.)	zeměpisná šířka (°s.š.)	nadmořská výška (m n.m.)
<b>Pod Voseckou boudou</b>			1180
VB-45	15,50873	50,77701	
VB-47	15,50870	50,77696	
VB-24	15,50894	50,77695	
VB-27	15,50906	50,77698	
VB-14	15,50901	50,77675	
<b>Pod Lysou horou</b>			1130
LH-28	15,51117	50,76151	
LH-33	15,51141	50,76154	
LH-37	15,51145	50,76156	
LH-39	15,51141	50,76166	
LH-58	15,51145	50,76171	
<b>Alžbětinka</b>			1192
A-F2	15,52022	50,75883	
A-F3	15,52031	50,75886	
A-F4	15,52029	50,75934	
A-C11	15,52051	50,75937	
A-C11b	15,52050	50,75937	
A-C12	15,52040	50,75934	
<b>Pudlava</b>			1240
P-P1	15,56387	50,76392	
P-P2	15,56391	50,76400	
P-P3	15,56387	50,76403	
P-P4	15,56382	50,76414	
P-P5	15,56412	50,76381	

Tab. 18: Počet trénovacích a kontrolních bodů

stanoviště	třída	počet trénovacích bodů	počet GTP
A	smrky	24	55
	louky	28	50
	holá půda	21	56
LH	smrky	23	172
	louky	36	189
	holá půda	18	15
LI	smrky	24	60
	louky	24	61
	nízká vegetace	20	41
	popadané stromy	17	31
	holá půda	23	56
MD	smrky	25	100
	louky	16	78
	nízká vegetace	19	63
	suťová pole	21	82
P	smrky	25	151
	louky	45	68
	popadané stromy	22	53
	holá půda	39	33
	skály	43	66
PA	smrky	32	96
	louky	28	75
	nízká vegetace	27	64
	popadané stromy, holá půda	52	118
	stín	21	39
V	smrky	61	234
	louky	68	107
	nízká vegetace	51	46
	popadané stromy	36	65
	holá půda	52	85
VB	smrky	25	282
	louky	47	191
	holá půda	28	59